



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY

A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

DETEKCE FIBRILACE SÍNÍ V EKG

EKG BASED ATRIAL FIBRILLATION DETECTION

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Vít Plch

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Marina Ronzhina, Ph.D.

BRNO 2019

Diplomová práce

magisterský navazující studijní obor **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

Student: Bc. Vít Plich

ID: 164993

Ročník: 2

Akademický rok: 2018/19

NÁZEV TÉMATU:

Detekce fibrilace síní v EKG

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši v oblasti automatické detekce fibrilace síní (FiS) v EKG záznamech. Popište parametry EKG a detekční metody, které lze pro tento účel použít. 2) Seznamte se s databází EKG signálů dostupnou na ÚBMI. Proveďte výpočet vybraných parametrů z EKG zdravých jedinců a pacientů s FiS. 3) Pomocí statistických testů určete parametry vhodné pro automatickou detekci FiS. 4) Navrhněte detektor FiS za použití vypočtených parametrů EKG a vybraného klasifikačního algoritmu. Navržený postup realizujte v prostředí Matlab. 5) Porovnejte výsledky s dostupnými údaji z literatury. Dosažené výsledky podrobně diskutujte.

DOPORUČENÁ LITERATURA:

[1] CURTIS, Michael J., Jules C. HANCOX, András FARKAS, et al. The Lambeth Conventions (II): Guidelines for the study of animal and human ventricular and supraventricular arrhythmias. Pharmacology and Therapeutics, Amsterdam: Elsevier Inc., 2013. roč. 139, vyd. 2, s. 213 – 248. ISSN 0163-7258.

[2] CLIFFORD, Gari D, Francisco AZUAJE a Patrick MCSHARRY. Advanced methods and tools for ECG data analysis. Boston: Artech House, 2006, 384 s. ISBN 1-58053-966-1.

[3] SAHOO, Sujit Kumar, Wenmiao LU, Sintiani Dewi TEDDY, Desok KIM, et al. Detection of atrial fibrillation from non-episodic ECG data: a review of methods. In 33rd Annual International Conference of the IEEE EMBS, Boston, USA, 2011, s. 4992-4995.

Termín zadání: 4.2.2019

Termín odevzdání: 12.8.2019

Vedoucí práce: Ing. Marina Ronzhina, Ph.D.

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

Tato diplomová práce se zabývá především detekci síňových fibrilací pomocí HRV, klasifikaci Poincarého mapy a následnému rozdělení do dvou skupin pomocí neuronových sítí. Výsledkem je potom rozhodnutí, které veličiny jsou statisticky významné pro identifikaci síňových fibrilací, které ne, a klasifikace signálu na základě těchto veličin pomocí Bayesovy a Lavenberg-Marquardtovy neuronové sítě. Při 23 neuronech ve skryté vrstvě má Bayesova síť nejlepší výsledky, a to $F1$ measure = 83,6 %, Senzitivita = 88,1 % a Specificitu 94,5 %.

Klíčová slova

Detekce síňové fibrilace, AF, RR Tachograf, Poincarého graf, Neuronová síť, SD 1, SD 2, R-R entropie, VAI, ROC, AUC

Abstract

This diploma thesis deals with detection of atrial fibrillation from HRV, classification of Poincare map and in the end the divide into two groups, one with detected atrial fibrillation and one not. The result is the decision on which variables are statistically significant for the identification of atrial fibrillations and which are not, and classification of the ECG signals with Bayes and Lavenberg-Marquardt neural networks. Bayes neural network with 23 neurons in hidden layer is best with $F1$ measure = 83,6 %, Sensitivity = 88,1 % and Specificity 94,5 %.

Keywords

Detection of atrial fibrillation, FIS, RR Tachograph, Poincare plot, Neural networks, SD1, SD2, R-R entropy, VAI, ROC, AUC

Bibliografická citace:

Plch, V. Detekce fibrilace síní v EKG. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2019. 63 s. Vedoucí práce: Ing. Marina Ronzhina, Ph.D.

Prohlášení

„Prohlašuji, že svou závěrečnou práci na téma Detekce fibrilace síní v EKG jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne **12. srpna 2019**

.....

podpis autora

Poděkování

Děkuji vedoucímu diplomové práce Ing. Marina Ronzhina, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne **12. srpna 2019**

.....
podpis autora

OBSAH

Obsah	7
1 Úvod.....	10
1 Elektrická aktivita srdce	11
1.1 Vznik membránového napětí.....	11
1.2 Převodní soustava srdce	12
1.3 Křivka EKG	13
1.4 Patologické změny v EKG	14
2 Detekce Fibrilace síní.....	16
2.1 Úvod do analýzy dat.....	16
2.2 Odvození příznaků z RR intervalu.....	17
2.3 Statistické vyhodnocení dat.....	22
2.4 Klasifikační metody	23
2.5 Ověření přesnosti detekce.....	27
3 Metoda pro automatickou detekci fibrilace síní v krátkodobých EKG záznamech	32
3.1 Popis EKG dat.....	33
3.2 Statistické testování diskriminačních schopností příznaků RR	34
3.3 Výsledky klasifikace EKG záznamů pomocí dopředné neuronové sítě	42
4 Závěr	50
Literatura	53

Seznam obrázků

Obr. 1 Převodní systém srdce [2]

Obr. 2 Složení signálů EKG z jednotlivých signálů částí převodní soustavy

Obr. 3 Znázornění druhů signálů [12]

Obr. 4 Poincarého mapa pacienta bez síňové fibrilace (vlevo) a pacienta se síňovou fibrilací (vpravo)

Obr. 5 Poincarého mapa pacienta klasifikována jako bez síňové fibrilace (ektopický signál)

Obr. 6 Nadhodnocení učení modelu příklad [24]

Obr. 7 5násobná křížová validace modelu, nahoře 1. krok, dole 2. krok

Obr. 8 Ukázka signálů firmy BTL, nahoře signál v dobré kvalitě dole potom signál nasnímaný chybně, nevhodný pro analýzu

Obr. 9 Grafy SD 1: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Obr. 10 Grafy SD 2: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Obr. 11 Grafy plochy elipsy: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Obr. 12 Grafy Směrodatné odchylky RR: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Obr. 13 Grafy střední hodnoty RR: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Obr. 14 Grafy krokování (stepping): Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Obr. 15 Grafy rozptylu (dispersion): Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Obr. 16 Grafy VAI: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Obr. 17 Grafy Entropie: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Obr. 18 Znázornění použitého perceptronu

Obr. 19 Graf průměrů F1 measure trénovacích množin s odchylkou v 5 opakováních

Obr. 20 Schéma vícevrstevných neuronových sítí s X skrytými neurony

Obr. 21 Závislost Směrodatné odchylky SD 2 [ms] na odchylce SD 1 [ms] detekované doktorem a pomocí funkce neuronových sítí v prostředí matlab (zelené – TP, modré – TN, červené – F)

Obr. 22 Závislost rozptylu [ms] na krokování [ms] detekované doktorem a pomocí funkce neuronových sítí v prostředí matlab (zelené – TP, modré – TN, červené – F)

Obr. 23 Závislost průměrného RR [ms] na směrodatné odchylce RR [ms] detekované doktorem a pomocí funkce neuronových sítí v prostředí matlab (zelené – TP, modré – TN, červené – F)

Obr. 24 Závislost Entropie [J/K] na VAI [°] detekované doktorem a pomocí funkce neuronových sítí v prostředí matlab (zelené – TP, modré – TN, červené – F)

Obr. 25 ROC trénovací skupiny dat (AUC = 0.98)

Obr. 26 ROC testovací skupiny dat (AUC = 0.957)

Obr. 27 Hodnoty F1 measure pro Bayesovu a LM metodu (1 až 50 neuronů)

ÚVOD

Fibrilace síní je jednou z mnoha patologických disfunkcí srdečního svalu, která může mít za následek selhání srdce, mozkové příhody i smrt. Je však také nejčastějším typem srdeční arytmie, který nemusí mít žádné projevy až vyústí ve vážné zdravotní komplikace. Je tedy nezbytné fibrilaci síní odhalit co nejdříve, abychom mohli zamezit tragickým následkům této nemoci.

Tato diplomová práce se věnuje detekci fibrilací síní, teoretickému rozboru několika principů automatické detekce fibrilace síní z elektrokardiografických záznamů. Především potom detekci pomocí pozic R vln, pomocí Poincarého grafu, a z něj vypočítaných parametrů. Dále jsou tyto parametry statisticky testovány a je ověřen jejich vliv na detekci. Nakonec je sestaven perceptron a víceúrovňová neuronová síť, pomocí nichž jsou data rozřazena na signály trpící síňovou fibrilací a na signály ostatní. V závěru jsou diskutovány výsledky těchto klasifikací a porovnání těchto výsledků s podobnými pracemi.

1 ELEKTRICKA AKTIVITA SRDCE

Tato kapitola je čerpána především ze zdroje [1].

Na všech živých buňkách je možné změřit elektrické napětí. Jeho velikost se liší podle druhu buňky, ale i podle jejího stavu. U srdečních buněk se velikost tohoto napětí v klidu pohybuje v rozmezí -70 až -80 mV se záporným nábojem uvnitř buňky. Toto napětí vzniká následkem rozdílné propustnosti iontových kanálů v membráně buňky. A rozdílnou koncentrací vně a uvnitř buňky. Vzrušivé buňky, mezi které patří i buňky myokardu, využívají změn tohoto napětí k šíření informací. Změna klidového napětí buňky nad její prahovou hodnotu vyvolá vznik akčního napětí. Tvar průběhu tohoto napětí potom určuje u jednotlivých buněk sílu kontrakce a dobu jejího trvání.

1.1 Vznik membránového napětí


Membránové napětí vzniká na fosfolipidových membránách všech živých buněk. Toto napětí je způsobeno především rozdílnou koncentrací iontů vně a uvnitř buňky. Tuto rozdílnou koncentraci umožňují bílkovinné útvary prostupující skrz membránu. Nazýváme je iontovými kanály. Protože hlavním kationtem intracelulárního prostředí je sodík a hlavním aniontem extracelulárního prostředí je draslík, je nejdůležitější sodíko-draslíkový kanál, také nazývaný sodíko-draslíková pumpa. Pumpa jej nazýváme proto, že neustále pumpuje ven z buňky sodík, a naopak do buňky draslík, protože se jedná o pohyb proti koncentračnímu spádu, spotřebovává tato pumpa neustále energii dodávanou ve formě ATP (adenosintrifosfát). Dalším důležitým kanálem je sodíko-vápníkový výměnný mechanismus, při němž se využívá koncentračního spádu sodíku, který se pohybuje směrem dovnitř buňky, a oproti němu se dostává vápník z buňky ven. Tato výměna se používá především v době kontrakce srdečního svalu, kdy je v intracelulární tekutině velké množství vápníkových iontů. Mimo kontrakci je však vápníku v buňkách přítomno méně a nedochází k výměně tak často.

Klidové napětí je na buňkách udržováno pomocí difúze přes iontové kanály vždy ve směru koncentračního spádu. Největší podíl na tomto jevu mají ionty draslíku, protože draslíkový kanál se na membráně vyskytuje nejčastěji. Po nějakém čase dojde k ustálení a vyrovnání sil koncentračního spádu a elektrostatických sil, působících v opačném směru proti koncentračnímu spádu. Tato rovnováha nastává právě při napětí mezi -70 až -80 mV při záporném náboji uvnitř buňky. U síňového myokardu se potom pohybuje v rozmezí od 65 do 70 mV. Pokud dojde k podráždění buňky vnějšími vlivy, dojde k šíření akčního potenciálu. U srdeční buňky k tomuto podráždění dochází elektrickým impulzem. Přesněji jde o depolarizaci o přibližně +5 mV. Následně se otevřou sodíkové kanály, jimiž začnou do buněk prudce proudit ionty sodíku, což zvedne napětí na membráně na +20 mV. Když při této velmi rychlé

reakci dosáhne napětí hodnoty přibližně -35 mV , dojde k otevření vápníkových kanálů. Tok vápníku je pomalý, a proto dokáže udržet napětí na membráně na hodnotě kolem 0 mV po dobu mezi 150 až 200 ms. Tuto dobu nazýváme fází plató a je typická pro srdeční buňky. Po této době se sodíkové i vápníkové kanály spontánně uzavírají a odeznívají i jím příslušné proudy. Aktivace a inaktivace iontových kanálů jsou tedy časově i napětově závislé děje.

1.2 Převodní soustava srdce

Schopnost vést akční potenciál mají sice všechny srdeční buňky, ale některé z nich se v průběhu vývoje přizpůsobily především k vedení proudu na úkor zmenšení své kontraktibility. Tyto buňky tvoří tkáň, které nazýváme převodní soustavou srdce. Do této soustavy patří postupně od místa vzniku signálu po směru jeho šíření (Obr. 1): sinoatriální uzel (SA), Hissův svazek, atrioventrikulární uzel (AV), levé a pravé Tawarovo raménko a Purkyňova vlákna.




Obr. 1 Převodní systém srdce [2]

Za normálních podmínek je počáteční vzruch generován v SA uzlu a šíří se všemi směry přes stěny síně k AV uzlu. Pokud by došlo k disfunkci SA uzlu je jeho funkce nahrazena AV uzlem a Hissovým svazkem, směr šíření vlny v síních se ale obrátí, a klidová tepová frekvence se zpomalí. AV uzel, Hissův svazek, Tawarova raménka a Purkyňova vlákna tvoří dohromady komorovou část převodní soustavy. AV uzel, ležící pod endokardem, na spodině pravé síně nad trojcípou chlopní, přechází svou dolní částí volně v Hissův svazek. Hissův svazek prochází přes nevodivou přepážku až na mezikomorové septum. Společně se nazývá AV uzel a Hissův svazek jako síňokomorová (AV) junkce. V Hissově svazku také dochází ke zpomalení, rozdělení a izolaci drah pro jednotlivé komory.

1.3 Křivka EKG

Pokud sečteme akční potenciály generované jednotlivými buňkami převodního systému, a vezmeme-li v úvahu i jejich zpoždění v čase, bude výsledkem elektrokardiogram, tak jak je vidět na Obr. 2. Z tohoto obrázku lze poznat, která část srdce způsobuje jednotlivé vlny a komplexy. Pokud jdeme zleva, počínaje vlnou P lze pozorovat že je ze začátku tvořena Sinusovým uzlem, z největší části ji tvoří signál síňového svaly a její konec tvoří A-V uzel. Změny na Hissově svazku nebo Tawarových raménkách se projeví na intervalu P-Q. Změny na Purkyňových vláknech se projeví na kmitu Q. Zbytek, tvořený z části vlnou Q a vlnami R, S a T, je tvořen z největší části komorovým svaem a ostatní jevy v této době svou amplitudou mnohonásobně převyšují.



Obr. 2 Složení signálů EKG z jednotlivých signálů částí převodní soustavy

1.4 Patologické změny v EKG

Vlna P je převážně kladná kulovitá vlna s výškou v rozmezí 0,1 až 0,15 (maximálně však 0,25) mV s trváním kratším než 100 ms. Pokud nalezneme vlnu P kladnou ve všech svodech, tak se jedná s největší pravděpodobností o sinusový rytmus. Pokud je vlna P alternující s frekvencí 50-60 min⁻¹, jedná se s největší pravděpodobností o projev putujícího pacemakeru. U vyšších frekvencí se potom jedná o multifokální zrychlený sinusový rytmus. Pokud v některých svodech nalezneme vlnu P negativní jedná se nejspíše o junkční (nodální) rytmus (vycházející z AV junkce). Pokud se výskyt vlny neprokáže, jedná se nejčastěji právě o vadu způsobenou síňovou fibrilací. Muže se však jednat i o další poruchy, jako je například flutter síní, sinoatriální blokáda, komorová tachykardie, supra ventrikulární tachykardie, fibrilace komor nebo flutter síní. Dalším patologickým projevem může být proměnlivá délka intervalů mezi údery srdce. Tyto údery pak nenastávají tak pravidelně, jako je tomu u sinusového EKG, ale podobně jako u sinusového EKG s ektopií (Obr. 3). Tato podobnost může způsobit chyby klasifikace signálu z RR intervalů.



Obr. 3 Znáznornění druhů signálů [12]

Interval P-Q měří se od začátku vlny P a končí na začátku kmitu Q, nebo taky komplexu QRS. Tento úsek udává dobu nutnou k doputování signálu od sinoatriálního uzlu ke svalovině komor. Považujeme ho za izoelektrický, protože z něj určujeme nulovou linii signálu. Trvání tohoto intervalu je za normálních podmínek v rozmezí 120–200 ms. Kratší interval nasvědčuje tachykardii (zrychlené tepové frekvenci) a delší naopak o bradykardii (zpomalené tepové frekvenci)

Komplex QRS je zobrazením průběhu depolarizace komor. Tato depolarizace je postupná, jako první probíhá depolarizace septa z levého Tawarova raménka, pak jsou depolarizovány subendokardiální vrstvy obou komor a vzruch se odtud šíří přes pracovní myokard až k epikardu. Komplex obsahuje obvykle 3 kmity P, Q a R. Normální trvání komplexu QRS je v rozmezí 60-110 ms. Prodloužení intervalu nad tyto hodnoty může být způsobeno blokádami Tawarových ramének, předčasnou komorovou excitací nebo idioventrikulárním rytmem.

Úsek ST je obvykle izoelektrický interval mezi koncem komplexu QRS a začátkem vlny T. Podstatou tohoto úseku je repolarizace komor (fáze plató). Počáteční bod tohoto úseku nazýváme jako junkční (značíme J) a normálně se tento bod vyskytuje ve stejné linii s počátkem komplexu QRS. V některých svodech je uváděna tolerance 0,05 mV. Elevace nebo deprese (zvýšení či snížení) úseku ST jsou považovány za projevy infarktu myokardu v akutním stádiu.

Vlna T je stejně jako úsek ST projevem repolarizace komor. Za normálních podmínek není vlna T kulovitého tvaru jako vlna P, ale má pozvolnější nástup a strmý sestup. Většinou je však také kladná, trvá přibližně 200 ms a její amplituda dosahuje 0,2-0,8 mV. Typická patologická vlna t pak může být například hluboká negativní vlna (vice než 0,5 mV), plochá nebo plošně negativní vlna, asymetrická negativní vlna nebo vysoká špičatá vlna T s úzkou základnou.

Vlna U je nalezená většinou 200-400 ms po ukončení vlny T. Její význam však není zcela jistý. Nález této vlny bývá fyziologický u sportovců a mladších pacientů.

2 DETEKCE FIBRILACE SÍNÍ

Základem této práce je rozlišit vstupní data s fibrilací síní od ostatních. Metod pro detekci fibrilací síní existuje velmi mnoho. Jednou je například detekce pomocí vlny P. Ta je lépe proveditelná pomocí lékařského personálu, ale pro implementaci v počítačových programech je metodou těžší. Proto je dále pojednávána metoda pomocí tachogramu EKG signálu. Tato metoda je testována na vstupních datech dostupných od firmy BTL Zdravotnická Technika, a.s. Pro detekci pomocí R-R intervalů je vždy nutné nejdříve detekovat pozice vln R. Zde je využito pozic přímo detekovaných elektrokardiografem, avšak jinak se využívá detekce pomocí lokální či globální metody, využívající buď pouze jeden svod nebo všechny dostupné svody. Je však ještě možnost využít jednoho svodu vytvořeného reprezentací ostatních signálů. Může ale nastat problém, že v jednotlivých svodech se vlna R promítne vždy v trochu odlišných časových momentech, a to kvůli rozdílnému umístění elektrod, ze kterých vyplývá rozdílná vzdálenost od daného místa a rozdílná doba šíření signálu k elektrodě. Proto této metody při této detekci nevyužíváme. Tato kapitola je zaměřena především na popis příznaků RR a metod pro automatickou detekci fibrilace síní.

2.1 Úvod do analýzy dat

Analýza dat je jednou z nejdůležitějších částí klasifikace signálu. Jde v ní především o studování souvislostí dat. Nejvšeobecnější název takovéto analýzy se dá shrnout jako „rozpoznávání obrazů“ přeložením z anglického výrazu „pattern recognition“. Jedná se však spíše o volný překlad, jelikož doslovný překlad by byl „rozpoznávání vzorů (schémat, šablon)“. Ty můžou být hodnoceny pomocí mnoha způsobů, například grafů, vektorů hodnot či soubory různých veličin. Jiným názvem mohou být například „vícerozměrné statistické metody“. Jde vlastně o soubor získávání různých spojitostí či skrytých jevů, mezi určitými soubory dat a následným rozřazením do skupin pomocí různých spojitostí v rámci jednotlivých skupin. Toto získávání veličin, které pomáhají rozdělit jednotlivé skupiny dat můžeme nazývat jako „data mining“ což je v překladu dolování či vytěžování dat. Jiný přístup je potom „machine learning“ rozšířený hlavně v poslední době. V překladu se tedy jedné o strojové učení. Což znamená, že část práce s nalezením podobností se dá implementovat do počítačových programů, které dokážou samy vytěžit část dat. Další možnosti jsou také neuronové sítě. Které jsou přesněji rozebrány až v dalších kapitolách této práce.

Cílem analýzy dat je tedy převážně posouzení zkoumaného objektu, na základě kterého je možné buď rozhodnout o typu či charakteru daného objektu, posoudit kvalitu tohoto objektu, anebo rozhodnutí o budoucí akci. Teoreticky se však jedná o stejnou nebo alespoň velmi podobnou úlohu. Data, která jsou na

začátku analýzy, se dělí na dvě skupiny. A to data buď spojitá (váha, délka a další) která je potřeba většinou před analýzou diskretizovat (kvantování, vzorkování) či data přímo diskrétní (barva, rasa, počet okvětních lístků, a podobné).

Dále je nutné nalézt vztahy mezi veličinami (klasifikačními příznaky), to ale znamená nalezení zákonitostí a podstat v rozloženích hodnot, závislostí mezi hodnotami použitých proměnných, nejlépe i nalezení matematického vztahu. Výsledky analytických výpočtů potom slouží k předzpracování dat ke klasifikaci, ale mohou být i přímo výsledkem zpracování, to například pokud výpočet přímo udává kvalitu předmětu. Obecně však způsob, jak určit klasifikační příznaky nesoucí nejvíce informace pro klasifikaci, není teoreticky formalizován [15][16]. Takže neexistuje teorie, podle které je možné předem určit, které veličiny nesou důležitou informaci, a které veličiny ne. Dnešní teorie však mohou poskytnout částečné řešení tohoto problému. Mohou pomoci buď vybrat minimální počet pro určitou přesnost ze souboru, nebo mohou pomoci vyjádřit původní skupinu veličin pomocí menšího počtu skrytých (latentních) proměnných, které nejde přímo změřit, avšak mohou být věcně interpretovány.

Konečným výsledkem analýzy potom bývá klasifikace, klasifikací rozumíme rozdělení jisté vstupní množiny objektů do konečného počtu skupin, který má dostatečně podobné společné vlastnosti (vstupní proměnné). Proto je však nutné předem stanovit jistá klasifikační kritéria, například předmět musí patřit pouze do jedné skupiny nikoliv do více skupin naráz. Klasifikace jsou prováděny vždy pomocí takzvaného klasifikátoru. Klasifikátor je postup (algoritmus), na vstupu kterého jsou data, popisující analyzované objekty, a jeho výstupem je potom zařazení do jednotlivých skupin na základě těchto vstupních dat.


2.2 Odvození příznaků z RR intervalu

Tachogram


Tachogram je jednoduchý graf znázorňující prodlevy mezi dvěma po sobě jdoucími R vlnami, jinak také tachogram HRV (heart rate variability). Na ose X bývá pořadí nasnímaného RR intervalu, na ose Y potom jeho velikost v ms. Nejčastěji se tento graf využívá při dlouho trvajících snímáních srdečního rytmu. V takovémto grafu je potom vidět například kolísající tepová frekvence, která způsobuje sinusové kolísání amplitudy tachogramu ale také jsou zde výrazné případné extrasystoly, protože délka mezi R vlnami je podstatně kratší, nebo scházející systoly komor, protože absence jedné systoly prodlouží interval mezi dvěma údery srdce téměř na dvojnásobnou délku. Z tachogramu lze odvodit celou řadu různých příznaků, a to v časové či frekvenční oblasti, příp. nelineární (viz Entropie níže).

Analýza Poincarého mapy

Analýza Poincarého mapy je geometrická nelineární analýza vycházející z tachogramu a slouží k popisu dat EKG z detekovaných vln R. Jedná se o grafickou reprezentaci časové posloupnosti vždy tří po sobě jdoucích úderů srdce do grafu a to tak, že dva po sobě jdoucí intervaly mezi třemi vlnami R jsou vyneseny do grafu jako jeden bod. Na ose x má vždy hodnotu délky intervalu R-R (n) a na ose y potom následujícího intervalu R-R (n+1). [7] Na Obr. 4 (vlevo) je vidět Poincarého mapa zdravého pacienta a na Obr. 4 (vpravo) je vidět Poincarého mapa při síňové fibrilaci.



Obr. 4 Poincarého mapa pacienta bez síňové fibrilace (vlevo) a pacienta se síňovou fibrilací (vpravo)



Obr. 5 Poincarého mapa pacienta klasifikována jako bez síňové fibrilace (ektopický signál)

Z principu této mapy je zřejmé, že čím delší úsek EKG máme k dispozici, tím jsou mapy vypovídající. Pokud máme velmi krátký úsek, může být graf nevypovídající. Z dat dostupných v této práci je potom zřejmé, že ne vždy se v tomto grafu musí fibrilace síní projevit stejnou změnou grafu. Například na Obr. 5 vidíme Poincarého mapu, která ukazuje signál, na němž nebyla klasifikována síňová fibrilace, avšak takovouto mapu připomíná. Jednou z možností zmiňovanou v článku [6] je detekce tohoto typického útvaru. Hlavním problémem špatné klasifikace v tomto případě však nejsou jen problémy s podobností map, ale především délka signálu. V rozsahu 10 sekund, je možné nasnímat mezi 7 až 30 R vlnami (při tepové frekvenci předpokládané mezi 42 až 180 tepy za minutu). Lépe se proto určují delší signály,

například trvající 5 minut, jako v literatuře [6]. Některé snímané signály mají však I méně než 4 R vlny. Proto bylo 16 signálů, které minimální délkou nevyhovují, vyřazeno z klasifikace. Může jít jak o špatný výpočet vlny R, tak o signál EKG znehodnocený šumem. Délka ostatních signálů byla potom při některých výpočtech zdvojnásobila, a to tak že vypočtené intervaly R-R byly zkopírovány dvakrát za sebe. Tím sice nepřibude signálu žádná nová informace, avšak je signál zbaven neurčitých hodnot při výpočtu s posuvným oknem, které požaduje pro svou správnou funkci minimální délku signálu. Tím je docíleno menší chybovosti než dopočítáváním náhodných podobných hodnot intervalů R-R.

Pro jednoduchost se snažíme popsat graf pomocí jeho číselných reprezentací. Nejčastěji se uvádí směrodatné odchylky ve směru pod úhlem 45°, označená jako SD_1 podle vzorce 2.2 [5], a 135°, označená jako SD_2 podle vzorce 2.3 [5]. Dále je vypočítaná plocha oválu S tvořená odchylkami SD_1 a SD_2 podle vzorce 2.4 [5]. Dále průměrný nárůst intervalu R-R na krok (stepping) podle vzorce 2.5 [6] a rozptyl kolem středového bodu (dispersion) podle vzorce 2.6 [6].

$$SD_1 = \sqrt{\text{std} \left(\frac{RR_i - RR_{i+1}}{\sqrt{2}} \right)} \quad 2.2$$

$$SD_2 = \sqrt{\text{std} \left(\frac{RR_i + RR_{i+1}}{\sqrt{2}} \right)} \quad 2.3$$

$$S = \pi \cdot SD_1 \cdot SD_2 \quad 2.4$$

Kde std(x) je směrodatná odchylka (standard deviation), RR_i je vektor R-R intervalů 1 až n-1 a RR_{i+1} je vektor R-R intervalů 2 až n+1.

$$\text{stepping} = \frac{\frac{1}{n-2} \sum_{j=1}^{n-2} \sqrt{(I_j - I_{j+1})^2 + (I_{j+1} - I_{j+2})^2}}{\frac{1}{n} \sum_{j=1}^n I_j} \quad 2.5$$

$$\text{dispersion} = \sqrt{\frac{\frac{1}{2(n-1)} \sum_{j=1}^{n-1} (I_j - I_{j+1})^2 - \left(\frac{1}{(n-1)\sqrt{2}} \sum_{j=1}^{n-1} |I_j - I_{j+1}| \right)^2}{\frac{1}{2(n-1)} (-I_1 - I_n + 2 \cdot \sum_{j=1}^{n-1} I_j)}} \quad 2.6$$

Kde n je počet bodu na Poincarého mapě, I_j je pozice j-tého bodu a I_{j+1} je pozice následujícího bodu.

Další získanou veličinou je VAI (vector angular index) který je podobný, ne však stejný jako SD₂. Jedná se o průměrnou odchylku ve stupních od úhlu 45° pro daný signál. A je vypočítán podle vzorce 2.7 [8]. Tato veličina reprezentuje odchylky úhlů jednotlivých bodů, svíraných mezi spojnicí bodu v Poincarého plotu s počátkem a osou x, od úhlu 45°. Z těchto hodnot je potom vypočítaný aritmetický

průměr. Hodnota je založena na předpokladu, že body v Poincarého plotu jsou umístěny blíže k úhlu 45° jako je znázorněno například na Obr. 4.

$$VAI = \frac{\sum_{i=1}^N |\phi_i - 45|}{N} \quad 2.7$$

Entropie

Nejdůležitější veličinou je potom entropie signálu, která však nevychází z Poincarého mapy, ale je počítána přímo z tachogramu. Tato veličina sama o sobě zaručuje efektivní a poměrně přesnou klasifikaci atriální fibrilace [14]. Teorie entropie vychází ze základních zákonů fyziky. První zákon je zákon o zachování energie, který říká že v uzavřeném systému energie nevzniká ani nezaniká ale pouze mění svůj stav. Druhý zákon termodynamiky říká, že se mechanická práce přeměňuje na teplo ale ne opačně. Při všech změnách energie se část energie systému mění na teplo a dochází k postupné ztrátě energie a tím k vzrůstu entropie. Z tohoto vztahu je entropie definována jako extenzivní složka tepla a popisuje degradaci tepla nastávající u nezvratných změn. Tuto degradaci lze chápat jako postupně ubývajícím schopnost práce. Entropie může v uzavřeném systému tedy pouze zůstat beze změny nebo stoupat a je též stavovou veličinou systému. [9]

Je však více možností, jak chápat entropii, a to třeba podle teorie informace. Kde je entropie jako míra neurčitosti (neuspořádanosti) systému [10]. Pokud budeme brát graf HRV (tachogram) jako zprávu, která nese informaci u stavu systému (buď má pacient atriální fibrilaci nebo ne) je vidět v signálu HRV určitá uspořádanost u pacientů s AF (pravidelnost po sobě jdoucích vzdáleností intervalů R-R, postupné narůstání, klesání) a u pacientů bez AF je vidět jistá nahodilost (neuspořádanost, nepravidelnost, nahodilost) signálu HRV. Nejběžnějším využitím entropie je její odhad [11]. Tuto metodu pro výpočet přibližné entropie (AppEN) navrhnul Pincus na krátkých zašuměných datech. Tato metoda přiřazuje nezáporná čísla pro signály s větší nepravidelností dat. Výpočet entropie určuje míru závislosti vstupu o délce N na předchozích m výstupech s tolerancí r , která určuje toleranci podobnosti dvou signálů. Tato metoda je v prostředí matlab interpretována funkcí *approxEnt* kde je nejdříve podle vzorce 2.8 vypočítána zpožděná rekonstrukce Y_{1-n} pro N vzorku dimenze m a potom podle vzorce 2.9 a 2.10 vypočítána přibližná entropie [21].

$$N_i = \sum_{i=1, i \neq k}^N 1(\|Y_i - Y_k\|_\infty < R) \quad 2.8$$

$$\Phi_m = (n - m + 1)^{-1} \sum_{i=1}^{N-m+1} \log(N_i) \quad 2.9$$

$$aproxEnt = \Phi_m - \Phi_{m+1} \quad 2.10$$

Vylepšením této metody je potom metoda vzorkové entropie (SampEn) [12] podle vzorce 2.11 [13].

Hlavními výhodami je že vzorková entropie nepočítá shody vzorků se sebou samými a to, že se nepoužívá při odhadu podmíněné pravděpodobnosti vzorec. Výsledky odhadu entropie a vzorkové entropie jsou velmi podobné.

$$SampEn(m, r, N) = -\ln \left[\frac{B^{m+1}(r)}{B^m(r)} \right] \quad 2.11$$

Další možností výpočtu entropie je víceúrovňová entropie (MSE) ve které je signál rozdělen pomocí koeficientů do bloků. Hodnoty entropie se pak počítají v úrovních signálu a jsou studovány v každé úrovni jednotlivě. Tato metoda je podobná zpracování signálu ve frekvenční oblasti. V této metodě je však potřeba podvzorkování signálu, a proto není vhodná pro velmi krátké signály, jako jsou v této práci, proto bylo použití této metody zamítnuto.

Pokud srovnáme tyto metody je přibližná entropie velmi závislá na délce signálu, což při velkých rozdílech v délkách signálů, jako jsou v datech od firmy BTL (až několikanásobné rozdíly), zavádí poměrně velkou chybu. Vzorková entropie je však navržena tak, aby právě tuto vadu přibližné entropie eliminovala. Zajímavé však je, že ačkoliv je každá následující entropie odvozena od předchozí udávají na sobě nezávislé výsledky. Nejdůležitější pro efektivitu entropie jako veličiny použité pro rozhodování při klasifikaci signálů je však volba parametru hranice podobnosti dvou vzorků – r . Proto je v pozdější části hodnota měněna v cyklu a jsou pozorovány výsledky klasifikace jako je plocha pod křivkou a F1measure.

Pro přesnější výpočet pomocí neuronových sítí je použita i průměrná délka intervalu R-R a směrodatná odchylka R-R intervalů použitých dat. Protože data obsahují velké množství EKG bez AF a pouze málo pacientů trpících AF je jako trénovací skupina pro neuronovou síť vybrána kombinace 150 pacientů s fibrilací síní a 1000 pacientů považovaných za zdravé, ve skutečnosti však všichni být zdraví nemusí, pouze nemají fibrilaci síní nebo jim nebyla klasifikována.

2.3 Statistické vyhodnocení dat

Abychom zjistily statistickou důležitost každého klasifikačního příznaku, musíme provést statistické testování a testování rozložení dat. Prvním testem je vykreslení dat pomocí krabicového diagramu (box plotu) vždy pro každý parametr zvlášť a to tak, že vlevo se nachází data s detekovanou atriální fibrilací a vpravo bez detekované fibrilace. Tyto grafy vykreslují všechna dostupná data.

Krabicové diagramy (vykreslené pomocí funkce *boxplot.m* a upravený pomocí funkce *boxploty.m*) jako jsou v kapitole 3.2 je schéma které poskytuje v jednom grafu informaci o maximální a minimální hodnotě, mediánu a horním a dolním kvartilu vstupních dat. Dolní a horní strana obdélníku (krabice) reprezentují dolní a horní kvartil. Dolní kvartil je hodnota, pod kterou leží přesně čtvrtina všech hodnot, zatímco horní kvartil je hodnota, nad kterou leží přesně čtvrtina všech hodnot. Mezi těmito kvartily potom leží mezikvartilové rozpětí, v němž leží medián. Medián, na obrázcích vodorovná červená čára, dělí potom data přesně na dvě poloviny. Tyto tři úsečky potom dělí data na zhruba stejně čtyři části. Dolní svislá úsečka (fous) potom odpovídá hodnotám ležícím pod krabicí, avšak pouze do maximální vzdálenosti jeden a půl násobku výšky krabice. Konec fousu (černá vodorovná čára) potom reprezentuje nejmenší hodnotu ze souboru. Naopak je to pak u horního fousu, který sahá také do jeden a půl násobku výšky grafu, a jeho horní vodorovná čára znázorňuje největší hodnotu souboru dat. Jak jde vidět z grafu jsou zde ještě červené body, ty reprezentují odlehlé hodnoty v grafu. [17]

Pro všechny data je potom vyhodnocen statistický nepárový t-test a kvůli jeho ovlivnitelnosti poměrem velikostí vstupních dat je vypočítán i Wilcoxonův test. Nepárový t-test je test pro data tvořené dvěma různými skupinami dat, která jsou vzájemně nezávislá. Což tomuto výběru dat vyhovuje. [18]

Pomocí Wilcoxonova testu testujeme dva výběry, přičemž testujeme veličiny jejichž rozdělení nemusí odpovídat Gaussovu normálnímu rozdělení. Testujeme potom hypotézu rovnosti jejich distribučních funkcí, na základě ověřeného symetrického rozložení. Nulová hypotéza předpokládá shodné mediány obou těchto rozložení, a proto se ji snažíme zamítnout. Zamítnutí nulové hypotézy potom znamená, že mediány obou rozložení nejsou shodné. Pro zamítnutí nulové hypotézy tohoto testu je potřeba aby výsledek vypočítaný pomocí funkce byl roven 1. U všech testů se potom snažíme, aby byla zamítnuta shoda mediánu a průměru. Tím se teoreticky potvrdí, že výběry nejsou shodné.

2.4 Klasifikační metody

Po tom, co jsou vybrány numerické reprezentace důležité pro klasifikaci dat, je nutné rozřadit vstupní data na základě těchto reprezentací na data trpící AF a ostatní. To lze mnoha způsoby jako například tvrdým prahem, klasifikačními stromy, metodou náhodných lesů nebo například neuronovými sítěmi.

Tvrký práh

Je nejjednodušší metodou klasifikace, ale právě to je i důvodem proč není nejlepší metodou při řešení klasifikace složitějších modelů. Princip této metody spočívá v určení určitého prahu ležícího vždy mezi maximální a minimální hodnotou vybrané veličiny. Hodnoty pod tímto prahem jsou potom zařazeny do jedné skupiny a hodnoty ležící nad tímto prahem do skupiny druhé. To ale znamená že pro data, jako jsou použita v této práci, je třeba tuto metodu upravit. Je třeba nejdříve klasifikovat každou numerickou reprezentaci (příznak) signálu samostatně. Tím dostaneme pro každý signál tolik příslušností do jednotlivých skupin jako je numerických reprezentací. Takto klasifikovaná data ovšem neodpovídají požadavku zařazení signálu pouze do jedné ze skupiny. Tento problém lze řešit například výběrem nejčastěji se vyskytující skupiny, kdy vybereme právě tu skupinu, do které je daný signál přiřazený nejčastěji. Toto řešení je nejjednodušší ne však nejpřesnější. Přesnější potom může být například vážení vstupů jednotlivými vahami vypočítané buď statisticky, na trénovací skupině, nebo odvozené na základě empirických znalostí. Největší váhu mají potom ty veličiny, které dokážou nejlépe rozdělit data.

Rozhodovací stromy

Klasifikace pomocí stromové struktury je potom založena na podobném základu. Stavebními kameny stromové struktury jsou uzly a větve. Na začátku je potřeba vždy sestavit rozhodovací strom, ale přístupů ke tvorbě stromů je velké množství (CART, CHAIT, PRIM, MARS atd.). Stromové struktury mají vždy určitá pravidla růstu stromu a ověřování správnosti sestavení stromu. Skupiny se postupně dělí na jednotlivé homogenní skupiny, strom potom prezentuje podobnost, vztahy a vzdálenost mezi jednotlivými skupinami. Po sestavení stromu je vždy dobré určit slabé větve a ty odstranit. Při klasifikaci pomocí stromové struktury se strom sestaví vždy pomocí trénovací skupiny a poté se jednotlivé signály z testovací skupiny rozřadí na základě hodnot jednotlivých numerických reprezentací do skupin. Každá stromová struktura přiřadí jednomu signálu vždy jednu výslednou skupinu. Pro větší přesnost potom slouží rozhodovací lesy. Princip rozhodovacích lesů spočívá v tom, že je sestaveno mnoho stromů. Metoda lesů předpokládá že čím více stromů potvrdí zařazení vstupních dat do skupin, tím je menší pravděpodobnost chyby v tomto zařazení. Některé metody potom nevyužívají stromy jen jednoho druhu, ale kombinují různé metody sestavování stromů [26].

Neuronové sítě

Jednou z nejpresnějších klasifikačních metod je metoda neuronových sítí. Tato metoda je však i jedna z nejsložitějších na správné nastavení. Princip této metody vychází z principu biologické neuronové buňky. Ta se skládá z buněčného těla, dendritu (vstupu) a axonu (výstupu), přičemž výstup jedné buňky bývá zpravidla napojen na vstup další. Na každý vstup potom buňka reaguje až při překročení předem určeného prahu.

Základním stavebním prvkem matematického modelu neuronových sítí je formální neuron. Formální neuron Y má obecně n reálných vstupů x ($x_1 \dots x_n$), které moderují dendrity. Tyto vstupy mají reálné váhy w ($w_1 \dots w_n$), které mohou být kladné či záporné. Záporné váhy potom reprezentují inhibici. Vnitřní potenciál každého neuronu (y_{in}) je potom dán váženou sumou všech jeho vstupů podle vzorce 2.12 [23].

$$y_{in} = \sum_{i=1}^n w_i \cdot x_i \quad 2.12$$

Pokud potom pracujeme s fixním prahem θ je výstup neuronu Y roven 1 jestliže je $y_{in} \geq \theta$ a roven 0 když je $y_{in} < \theta$. Vstupy neuronu mohou být chápány jako souřadnice bodu v n -rozměrném euklidovském prostoru. Pokud $n=2$ (prostor je rovina) rovnice neuronu je přímka, pro $n=3$ je rovnice rovina. Tato rovnice neuronu dělí potom prostor vždy na dvě části, a to část nad touto rovinou kdy je výstup neuronu Y roven 1 a pod rovinou, kdy je roven 0.

Důležitou částí každé neuronové sítě je potom její učení. Učení neuronové sítě znamená adaptace vah jednotlivých vstupů a prahu neuronu na vstupní data tak, aby výstup neuronu odpovídal vždy předpokládané hodnotě pro daný problém. Principů učení je mnoho, nejjednodušším je například Hebbovo pravidlo, podle něž váhové hodnoty na spojení mezi dvěma neurony v dalším kroku narostou, pokud jsou tyto neurony současně ve stavu 1, a naopak budou váhy klesat, pokud budou neurony současně ve stavu 0. Hodnoty vah v dalším kroku jsou potom vypočítány podle vzorce 2.13.

$$w_i(\text{nový}) = w_i(\text{starý}) + x_i \cdot y \quad 2.13$$

Neuronové sítě se potom obdobně jako u biologických sítí skládají z neuronů jejichž výstup bývá vstupem zpravidla pro více než jeden neuron. Počet neuronů a jejich vzájemné uspořádání potom vytváří architekturu neuronové sítě. Tyto architektury se dále dělí do dvou skupin, a to buďto na cyklické (rekurentní) nebo acyklické (dopředné). U cyklické neuronové sítě vzniká v topologii vždy alespoň jedna cesta mezi neurony, která tvoří uzavřený okruh. To znamená že například výstup jednoho neuronu je zároveň vstupem druhého neuronu, výstup druhého neuronu je zároveň vstupem neuronu prvního. Naopak u sítě acyklické neexistuje žádná uzavřená cesta mezi neurony. Takovéto acyklické sítě lze potom vždy rozdělit do disjunktních

vrstev, které lze zobrazit do jednotlivých řad nebo sloupců. První vrstvu potom nazýváme vstupní a poslední vrstvu nazýváme výstupní. Všechny vrstvy mezi vstupní a výstupní nazýváme skryté vrstvy neuronové sítě. Díky tomu, že jsou neurony každé vrstvy vícevrstvé neuronové sítě propojeny se všemi neurony vrstvy bezprostředně následující lze topografii těchto sítí zapsat pouze pomocí počtu neuronů v jednotlivých vrstvách, a to tak, že na první pozici je zapsán počet neuronů ve vrstvě vstupní za ním jsou zapsány postupně od vstupní vrstvy po vrstvu výstupní jednotlivé počty neuronů ve skrytých vrstvách a jako poslední je zapsán počet neuronů ve vrstvě výstupní.

Topologie sítě potom může být aktivní (v čase proměnná) nebo statická (časově neměnná). Aktivní dynamika určuje počáteční stav sítě a způsob její změny v čase. Většinou u změny nepředpokládáme spojitý čas, který je zadáný diferenciálními rovnicemi, ale čas diskrétní. V každém kroku diskrétního času může síť měnit buď jen jeden neuron (sekvenční výpočet) nebo více neuronů najednou (paralelní výpočet). Modely mohou být rozlišeny i podle toho, zda se neurony sítě mění nezávisle na sobě, potom je takováto síť asynchronní, nebo jsou změny neuronů řízeny centrálně, potom je síť synchronní. U aktivní sítě potom hledáme takový stav sítě, který se po určitém počtu iterací dále v čase nemění (je konstantní).

Adaptativní dynamika je potom princip, který předpokládá určitou vstupní (trénovací) množinu sítě. Na začátku výpočtu se všechny váhy neuronů nastaví na určitý počáteční stav (například náhodný). Všechny možné konfigurace vah sítě potom nazýváme váhový prostor. Cílem adaptativní dynamiky je potom nalézt právě takovou konfiguraci sítě ve váhovém prostoru která při aktivní dynamice realizovala požadovanou funkci. Cílem adaptativní dynamiky je tedy nastavit síť tak, aby aktivní dynamika vypočítala z daného vstupu předpokládaný výstup. Trénovací množina sítě většinou obsahuje dvojice vstup a výstup. Takovému učení sítě se potom říká učení s učitelem. Ale pokud obsahuje pouze množinu vstupů, adaptuje se síť tak, aby rozřadila vstupy na výstupy do několika shluků podle jejich vzájemné podobnosti. Takovému učení potom říkáme učení bez učitele.

Perceptron

Je nejjednodušší neuronovou sítí s právě jedním neuronem ve skryté vrstvě a n vstupy. Ke každému vstupu je přiřazena váha w_n . Výstupem vstupních neuronů přiváděným společně na vnitřní neuron jsou potom buď binární hodnoty (1 nebo 0), nebo hodnoty bipolární (1, 0 a -1). Výstupem perceptronu je pak 1 pro hodnoty větší než práh θ , 0 pro hodnoty mezi θ a $-\theta$, a -1 pro hodnoty menší než práh $-\theta$. Učení perceptronu potom probíhá podle adaptačního pravidla tak, aby byl minimalizován rozdíl mezi výstupy perceptronu a požadovanými hodnotami. Jinou neuronovou sítí může být například Adaline (adaptativní lineární neuron), který se od perceptronu liší především tím, že dělí prostor pouze na dvě části. Jedna část je nad prahovou rovinou, a druhá je pod ní. Madaline (multiple adaptive linear neuron) je potom

složitější neuronová síť. Skládá se ze dvou a více Adaline neuronů. Tato síť je vhodnější k řešení komplikovanějších problémů, jelikož nedělí prostor pouze na dvě části, ale dokáže definovat prostorové útvary. Adaptivní algoritmus Madaline nazývaný MRI. Tento algoritmus mění pouze vstupní váhy neuronů ve vnitřní vrstvě, zatímco váhy vstupních neuronů se při adaptaci nemění. Tato metoda byla později vylepšena na MRII která adaptuje všechny váhy neuronové sítě.

Klasifikace (rozpoznávání) vzorů je velmi důležitou aplikací teorie neuronových sítí. V této aplikaci je potřeba nejdříve určit charakteristické rysy objektů a vytvořit charakteristické vektory. Dále je potřeba určit rovnici rozlišovací funkce (nadroviny). To bývá v praxi zpravidla nejtěžší část. Existuje však mnoho způsobů jak určit tvar této funkce, a to například metodou nejbližších sousedů, lineární klasifikací, statistickými technikami a podobně. Lineární metody jsou pak aplikacím umělých neuronových sítí nejbližší [23].

Feedforward

Metoda feedforward (dopředné plnění sítě) je často používaná metoda aplikací neuronových sítí. S dostatečným konečným množstvím neuronů ve vnitřní vrstvě sítě dokáže řešit jakýkoliv konečný problém vstup – výstup.

Backpropagation

Jejím vylepšením je potom metoda backpropagation (zpětné šíření chyby). Tato metoda je vůbec nejčastěji používanou metodou (cca 80 % všech použití neuronových sítí). Metoda zpětného šíření chyby se dělí na 3 hlavní části a to:

1. Dopředné naplnění sítě daty z testovací skupiny (feedforward)
2. Zpětné šíření chyby
3. Aktualizace váhových hodnot spojení neuronové sítě

Při dopředném plnění sítě se každému neuronu vstupní vrstvy jemu příslušný vstupní signál. V následujícím kroku se vypočte aktivace vnitřních neuronů a odešle se na neurony výstupní. Poté vypočítají svou aktivaci výstupní neurony. Hodnota této aktivace odpovídá skutečné odpovědi sítě. Dále je podle předpokládaného výsledku sítě dopočítána chyba (například metodou nejmenších čtverců) neuronové sítě a z ní je zpětně dopočítána chyba každého z neuronů. A posléze upraveny váhy jednotlivých neuronů. Důležité jsou především aktivační funkce. Tato funkce musí být spojitá, diferencovatelná a monotónně neklesající. Nejčastěji je proto logická sigmoida a hyperbolický tangens [23]. K optimalizaci chyby se potom nejčastěji používají gradientní metody, a to zejména pro jejich jednoduchost. Gradientní metody využívají derivaci (tečnu v bodě chybové funkce), pomocí níž se pokračuje v nastavení vah směrem k předpokládanému poklesu chybové funkce. Tímto způsobem je vyhledáváno nastavení vah s minimální chybou. Problémem však může

být, že vyhledané lokální minimum nemusí být minimem globálním. Tato chyba se dá napravit opakovaným učením sítě, protože při náhodném rozmístění vah je pravděpodobnost ukončení trénování sítě v globálním minimu větší než při jednom pokusu. Metody učení bez učitele nejsou v této práci více probrány jelikož je k dispozici trénovací množina.

2.5 Ověření přesnosti detekce

K ověření přesnosti detektoru jsou v této práci použita především 4 hlavní kritéria a to senzitivita, specifická, plocha pod křivkou (AUC, z anglického area under curve) a nejefektivnější hodnota reprezentující kvalitu klasifikace je F1 measure.

Senzitivita a specifická

Senzitivita (2.14) a specifická (2.15) jsou podobně vypočítané veličiny používané pro hodnocení diagnostických testů. Pokud test určuje u osoby přítomnost určitého onemocnění jako je například v této práci AF. Sledujeme potom zda určitá osoba opravdu tímto onemocněním trpí a test ji odhadne jako nemocnou, v tom případě řadíme pacienta do skupiny správně pozitivních (TP, true positive). V dalším případě může být osoba zdravá a test ji určí jako zdravou, tehdy se pacient zařadí do skupiny správně negativních (TN, true negative). U zbylých dvou klasifikací se potom jedná o chyby, a to buď chyby typu 1, neboli falešně pozitivní (FP, false positive), u této chyby jde o to, že pacient nemocí netrpí, ale je mu testem predikována. Pacient pak, pokud nebudou udělány jiné testy, které predikci zamítnou, může být léčen na nemoc kterou netrpí. A poslední skupinou jsou potom chyby typu 2, u nichž je pacient, který onemocněním trpí určen jako zdravý, jedná se o výsledek ze skupiny falešně negativních (FN, false negative). V takovém to případě může neléčení nemocného pacienta vést ke zhoršení jeho stavu, až k smrti. Z těchto skupin hodnocení testu se potom dá vypočítat mnoho veličin určujících kvalitu testu. Pro tuto práci je potom nejdůležitější právě senzitivita, což je schopnost testu rozpoznat všechny skutečně nemocné osoby. Jedná se tedy o pravděpodobnost, že test bude u nemocné osoby skutečně pozitivní. A specifická testu, která udává schopnost testu rozeznat všechny zdravé osoby a je to tedy pravděpodobnost, že test bude mít u zdravé osoby negativní výsledek [19].

$$\text{Senzitivita} = \frac{TP}{TP + FN} \quad 2.14$$

$$\text{Specifická} = \frac{TN}{TN + FP} \quad 2.15$$

Plocha pod křivkou je hodnota vypočítaná ze regresivně operativní křivky (ROC, regression operative curve). Na základě předchozích hodnot nemůžeme hodnotit spojité výstupy. K tomu slouží ROC analýza. Díky této analýze můžeme zjistit jak

vhodné veličiny pro samotné rozdělení dat do skupin, tak můžeme pomocí plochy pod touto křivkou hodnotit, jak dobře test diskriminuje dvě skupiny od sebe. V této analýze jde o to, že posunujeme dělicí práh (cut-off) přes všechny hodnoty vstupní proměnné a interpretujeme hodnoty pod prahem jako zdravé jedince a hodnoty nad prahem jako nemocné. Potom pro výsledky sestrojíme graf jako závislost senzitivity na převrácené hodnotě specifity (FP rate, false positive rate). Pokud by potom klasifikace určila správně pouze polovinu dat (tzn senzitivita a specifita je 0.5) byla by ROC křivka takovéto klasifikace shodná s přímkou pod úhlem 45°. Metoda předpokládá že k takovému výsledku lze dojít právě náhodným výběrem, kdy se jedna polovina určí náhodně jako zdravá a druhá jako nemocná, bez závislosti na vstupních parametrech. Ideální graf dokonalé analýzy by potom vypadal tak, že do určitého prahového bodu by byla senzitivita rovna jedné a hodnota 1 - specifita (FP rate) rovna 0, zatímco od tohoto bodu dále by byla 1 - specifita (FP rate) rovna jedné a senzitivita rovna 0. Takovýto test by potom přesně v prahové hodnotě určil všechny pacienty správně. V praxi nám však musí postačit se takovéto hodnotě co nejvíce přiblížit. Plocha pod takovýmto grafem je přímo rovna 1, přičemž při horší detekci se plocha pod křivkou (AUC) zmenšuje. Tohoto principu využíváme při hodnocení kvality grafu podle plochy pod křivkou. I když tato hodnota není přesně vypovídající pro může být hodnota velmi blízká 1, ale bodu (1,0) se může vzdáleně vyhnout, a navíc je metoda ovlivnitelná nehomogenními daty, kdy jedna skupina je mnohem větší než druhá. To proto, že hodnota AUC nevypovídá přímo o tvaru této křivky.

F1 measure

Proto používáme další kritérium F_1 measure. Toto kritérium je používáno pro kvalifikaci správnosti klasifikace dat. Díky výpočtu tohoto kritéria můžeme porovnat výsledky klasifikace se soutěží „PhysioNet/Computing in Cardiology Challenge 2017” [20]. Zde jsou však data rozdělovány do čtyřech typů, normální signály, AF signály, ostatní rytmy a zašuměné signály, takže hodnoty klasifikace mohou být v soutěži o něco nižší (více skupin znamená více možností špatného zařazení). Pro tuto práci však stačí pouze dělení do dvou skupin, a to signály s AF a ostatní. Většina zašuměných signálů byla vyřazena ručně, a zbytek byl vyřazen kritériem podmiňujícím alespoň 4 a více R vln. Pro každou ze skupin bylo potom vypočítáno kritérium podle vzorce 2.16. Kde F_{1a} je hodnota F_1 measure pro klasifikaci atriální fibrilace, ΣA_a je počet všech AF signálů klasifikovaných jako AF (TP), ΣA je počet všech signálů klasifikovaných jako AF a Σa je suma všech signálů predikovaných jako AF. Pro ostatní bylo potom vypočítáno kritérium obdobně. V poslední řadě potom dopočítáme z jednotlivých výpočtu celkovou F_1 measure jako aritmetický průměr těchto dvou hodnot.

$$F_{1a} = \sum \frac{2 * \Sigma A_a}{\Sigma A + \Sigma a} \quad 2.16 [20]$$


Na základě těchto čtyř hodnot, především pak právě na základě F_1 , byly odladěny vstupní hodnoty jako je prahová hodnota r pro entropii, množství vnitřních neuronů ve skryté vrstvě neuronové sítě, způsoby rozhodování neuronové sítě, jako je dopředná síť (*feedforwardnet*), *perceptron*, nebo nastavení neuronové sítě pro samotné rozpoznávání vzorů (v matlabu funkcí *patternnet*), které je jinak součástí dopředné sítě. Pro odhalení nejlepšího nastavení pro klasifikaci slouží funkce *odladieni.m* v níž jsou pomocí cyklů postupně měněny vstupní veličiny a do tabulky jsou zapisovány výsledky jednotlivých funkcí přesnosti. Posléze je vybrána největší hodnota F_1 measure a na základě její pozice zjištěna ideální kombinace vstupních parametrů pro nejlepší výsledek.

Ověření správnosti modelu

Ve strojovém učení nebo umělé inteligenci bývají data rozdělena do dvou skupin, na trénovací a testovací. Model je naučen na trénovacích datech a přesnost je vyhodnocena na datech testovacích. V tomto případě ale může dojít ke vzniku stavů jako je over-fitting nebo under-fitting (čili nadhodnocení nebo podhodnocení trénovacích dat). Nadhodnocení znamená, že je model příliš přesně nasazen na trénovací data (vč. Všech obsažených chyb) a není pak schopen rozpoznat data nová nebo testovací. Cílem křížové validace je eliminovat tyto dva nežádoucí stavy. Základem křížové validace je rozdělení tréninkové sady na další dvě. Sadu pro trénování a sadu pro validaci. Model je trénován podle nové trénovací sady a predikce na validačním setu dat je využita k určení přesnosti modelu. [24]

Nadhodnocení učení modelu

Obvykle nastává, když je model příliš komplexní. Tento model pak mívá vysokou přesnost pro trénovací data, ale nízkou přesnost pro data testovací či nová. Model je zde naučen na šum obsažený v trénovacích datech namísto reálných závislostí k dané třídě. Tento šum nemusí být obsažen v datech testovacích či nových a nastává problém tato data rozpoznat. Ukázka nahodnocení je zobrazena na Obr. 6, kde od 200 iterace dochází k rapidnímu snížení chyby trénovacího setu dat, ale zároveň k rapidnímu zvýšení chyby testovacího nebo validačního setu dat. Ideální se zde jeví proces učení zastavit na 200 iteraci. [24]



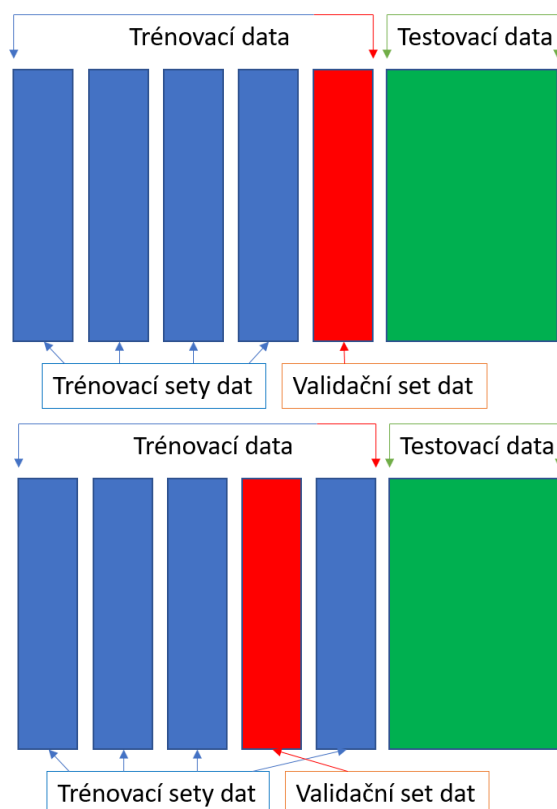
Obr. 6 Nadhodnocení učení modelu příklad [24]

Podhodnocení učení modelu

K podhodnocení dochází naopak pokud model není dostatečně naučen na trénovací data. To může nastat v případě velmi jednoduchého modelu, který nemá dostatek nezávislých příznaků. Ve výsledku tento model taktéž nedokáže správně vyhodnotit testovací nebo nová data. [25]

K-násobná křížová validace modelu

Používá se k určení nejlepší složitosti modelu, např. ke stanovení hloubky rozhodovacího stromu nebo počtu skrytých jednotek v neuronové síti. K-fold metoda je často využívána, neboť je dobře interpretovatelná a vede k obecně lepším výsledkům, než například náhodné rozdělení na testovací a trénovací set dat. K-fold validace má jediný parametr nazvaný k , který udává do kolika skupin se má trénovací set dat rozdělit. Pokud je vytvořeno k množin dat, model je trénován na $k-1$ setech dat. V případě $k=5$ se jedná o 5násobnou křížovou validaci. To v praxi znamená, že je vytvořeno 5 setů dat, přičemž model je trénován na 4 setech dat a přesnost tohoto modelu je vyhodnocena na 1 zbývajícím setu dat jako na Obr. 7. Nahoře je 1. krok, pod ním potom 2. krok a v následujících krocích se pokračuje obdobným způsobem. Testovací skupina celkového modelu potom není do výpočtu nijak zahrnuta. [25]



Obr. 7 5násobná křížová validace modelu, nahoře 1. krok, dole 2. krok

Výsledek trénování na k -fold validaci slouží k ověření učení modelu, a to tak, že průměrný vypočtený parametr, například sensitivita, specificita či F1 measure. Je potom stabilnějším parametrem, než při „jednorázovém“ testování při náhodném rozdělení modelu na dvě skupiny. K popisu validace učení se dá také použít směrodatná odchylka dat. Ta posléze určuje, jestli je vypočtený parametr při opakování trénování podobný, nebo má velký rozptyl hodnot. Pokud je rozptyl hodnot velký, může to vypovídat buď o špatném rozložení vstupních dat nebo o špatném nastavení výpočtu sítě, které nezaručuje stabilní přesnost výpočtu při více opakováních. Takovému výsledku se tedy nedá důvěřovat, neboť jednou je výpočet přesný a jindy nikoliv.


3 **METODA PRO AUTOMATICKOU DETEKCI FIBRILACE SÍNÍ V KRÁTKODOBÝCH EKG ZÁZNAMECH**

V této části jde o výběr příznaků vhodných ke klasifikaci a rozřazení jednotlivých EKG pomocí vybraných klasifikačních metod na signály, které jsou postiženy fibrilací síní a signály ostatní. K tomu můžeme použít tvrdého prahu, rozhodovacího stromu nebo neuronových sítí. Tvrdý práh pro jednotlivé veličiny je použit v kapitole 5.2 při sestrojení křivek ROC. Klasifikace podle rozhodovacího stromu v této práci není blíže probírána a to proto, že při jejím zkoušení v programu nebylo dosaženo dostatečné přesnosti (F1 measure = 67,33 %). Ačkoliv úspěšnost na trénovací skupině dosahovala až k dokonalému AUC (při přeučení), na skupině testovacích dat vyšla přesnost klasifikace vždy hůře, než u neuronových sítí. Proto byly všechny výstupy analýzy, které prošly statistickým testováním použity jako vstupy pro neuronovou síť (v matlabu funkce *train*) pro která byla pomocí cyklu vybrána nejlepší síť a její nastavení. Trénování této sítě je otestována pomocí 5fold validace modelu. Všechny trénovací data jsou před každým opakováním učení modelu náhodně promíchány, což snižuje statistickou pravděpodobnost náhodného dobrého výsledku trénování skupiny. Toto trénování je potom opakováno pětkrát a je vypočtený průměrný výsledek F1 measure. Z průměrného výsledku je určeno nejlepší nastavení sítě. Pro učení výsledného modelu je potom použita celá trénovací skupina. Nakonec je vypočtena i odpověď na testovací množinu, včetně průměru a směrodatné odchylky F1 measure.

3.1 Popis EKG dat

Data pro tuto práci jsou dostupná od firmy BTL zdravotnická technika a.s. jenž je celosvětově známou firmou, a je dodavatelem mnoha terapeutických i diagnostických elektrotechnických zařízení využívaných v nemocnicích po celém světě. Data od této firmy jsou nasnímány v klinickém prostředí pomocí 12 svodového elektrokardiografu. Signály byly původně ve formátu .xml a proto bylo nejdříve nutné je převést do formátu vhodného k dalšímu zpracování v prostředí programu matlab. Tyto programy byly dostupné od vedoucího této práce.

Původních signálů firmy BTL bylo 6884, avšak některé jsou nevhodné nasnímané, překryté rušením nebo jinými chybami (Obr. 8 dole). Po vymazání nevhodných signálů zbylo 6830 použitelných signálů, z toho je 442 signálů určených odborným lékařem jako postižených síňovou fibrilací (AF) a 6238 jako signálů bez AF. Signály bez AF však mohou být zatíženy jinými srdečními vadami. Data jsou snímány v klinickém prostředí s vzorkovací frekvencí 500 Hz a délkou signálu 10 s. Dále jsou z dat vyjmuty pouze pozice R vln detekované přímo elektrokardiografem

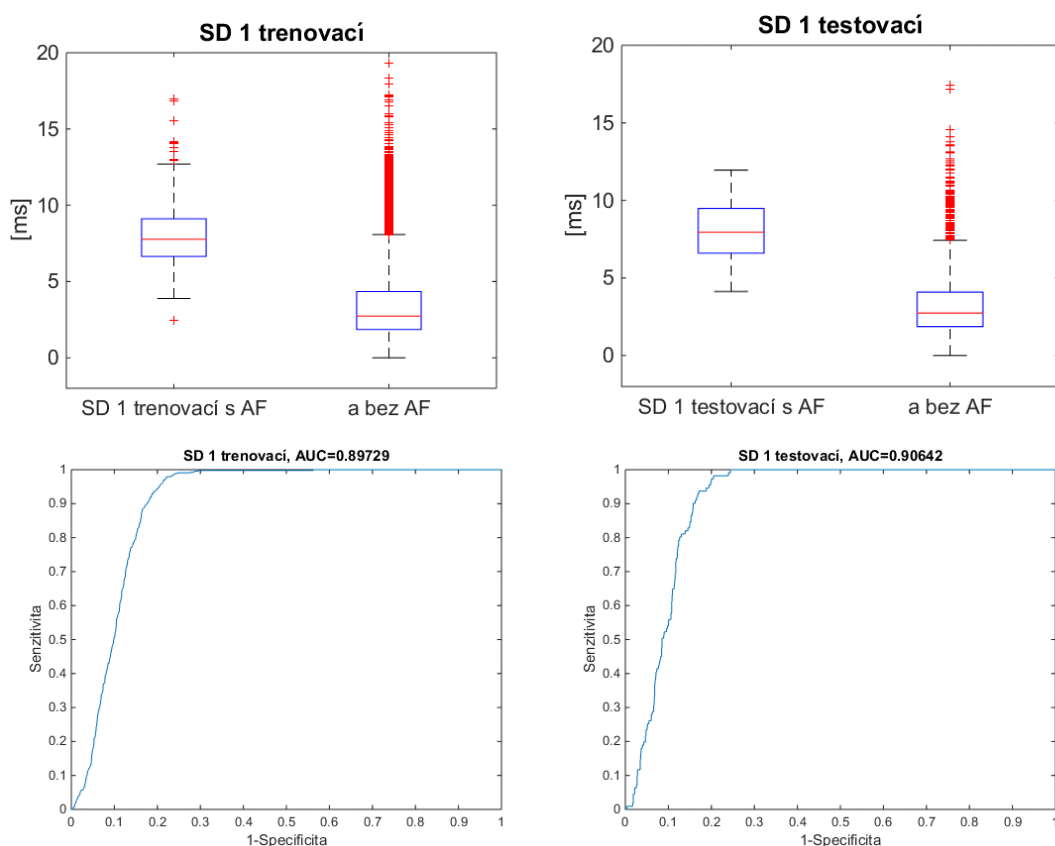


Obr. 8 Ukázka signálů firmy BTL, nahoře signál v dobré kvalitě
dole potom signál nasnímaný chybně, nevhodný pro analýzu

firmy BTL uložených pomocí funkce grsSave.m do souboru BTL_qrs.mat a je použita tabulka indAfibTrainTest.mat ve které jsou uloženy finální klasifikace pro jednotlivé signály a jejich zařazení do trénovací nebo testovací skupiny. Při praktické části jsou náhodně promíchány tak, aby simulovali náhodné uskupení návštěvníků kliniky. Z celkem 6884 signálů je 4991 (73 %) signálů bez atriální fibrilace a 442 (7 %) signálů s atriální fibrilací vybráno jako trénovací skupina (80 %). Signály na trénování a testování jsou vybrány předem. Pro lepší trénování neuronových sítí je vektor signálů s atriální fibrilací zkopírován 10krát (4450 signálů) za sebou, aby byly obě skupiny přibližně stejně dlouhé a následně jsou náhodně promíchány. Do testovací skupiny (20 %) bylo potom vybráno 1247 (18 %) signálů bez AF a 111 (2 %) s AF.

3.2 Statistické testování diskriminačních schopností příznaků RR

V této kapitole jsou blíže rozebírány výsledky statistických testů upřesněných dříve v kapitole 2.4. Jsou doplněny krabicovými grafy pro jednotlivé skupiny vstupních dat a numerické reprezentace jednotlivých signálů.

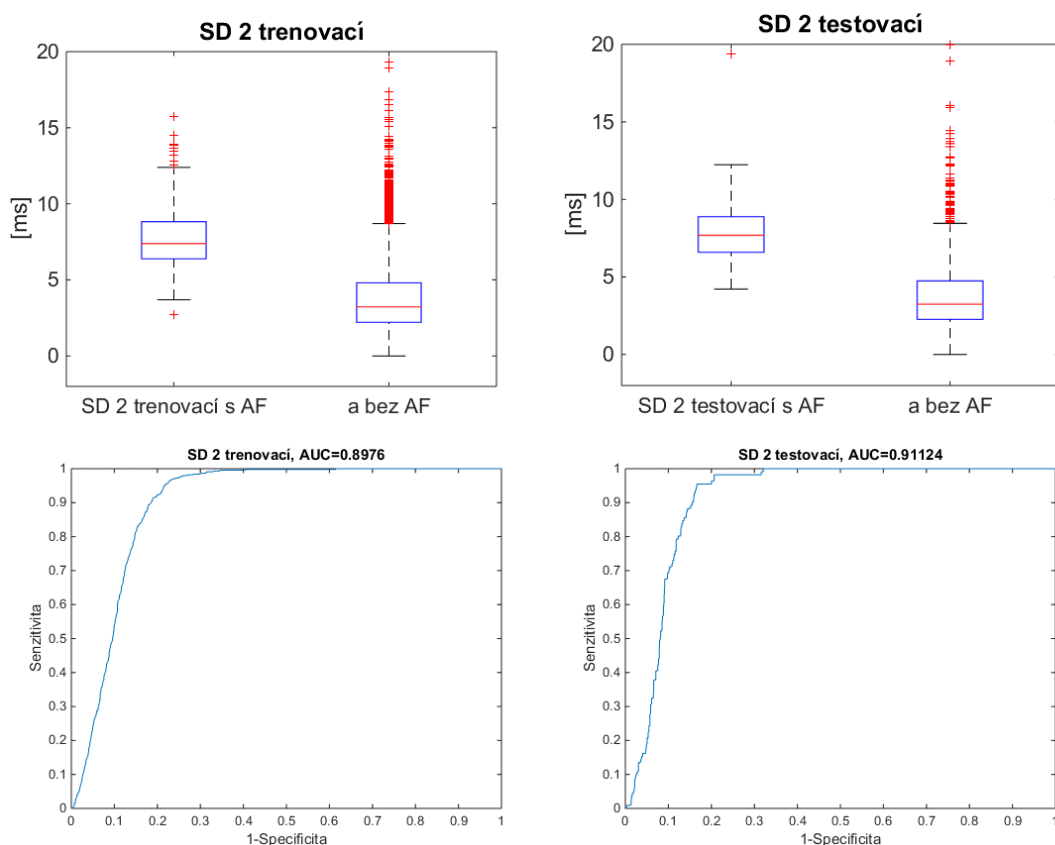


Obr. 9 Grafy SD 1: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Jak lze vidět z box plotů (na Obr. 9), trénovací i testovací skupiny se překrývají. Největším problémem je zde velké množství odlehlých hodnot ve skupině bez detekovaných AF. Proto jsou trénovací data testována pomocí dvou-výběrového nepárového t-testu a wilcoxonova testu. A to vždy data s Fibrilací proti datům bez fibrilace pro každou reprezentaci zvlášť. Pro data byla použita nulová hypotéza, která předpokládá shodné střední hodnoty obou skupin. Pokud se nám podaří zamítnout nulovou hypotézu, na hladině významnosti $\alpha=5\%$, a přijmout hypotézu alternativní. Můžeme tedy prohlásit, že tyto dva výběry mají statisticky prokazatelně rozdílné střední hodnoty (i mediány). To znamená že se hodí k rozlišování dat zatížených AF od dat bez AF. V prostředí matlab k tomuto slouží funkce *ttest2*. Výsledek t-testu je $h=0$ a výsledek wilcoxonova testu je $h=1$. Na základě těchto testů byla pro směrodatnou odchylku ve směru diagonály (SD 1)

nulová hypotéza zamítnuta. To znamená, že byla přijata hypotéza alternativní, a lze prohlásit, že je SD 1 veličinou statisticky významnou pro rozlišování AF. Ve spodní části Obr. 9 lze potom vidět, že AUC pro hodnotu SD 1 je přibližně 0.9, to znamená, že hodnota sama o sobě poměrně dobře rozděluje obě tyto skupiny.

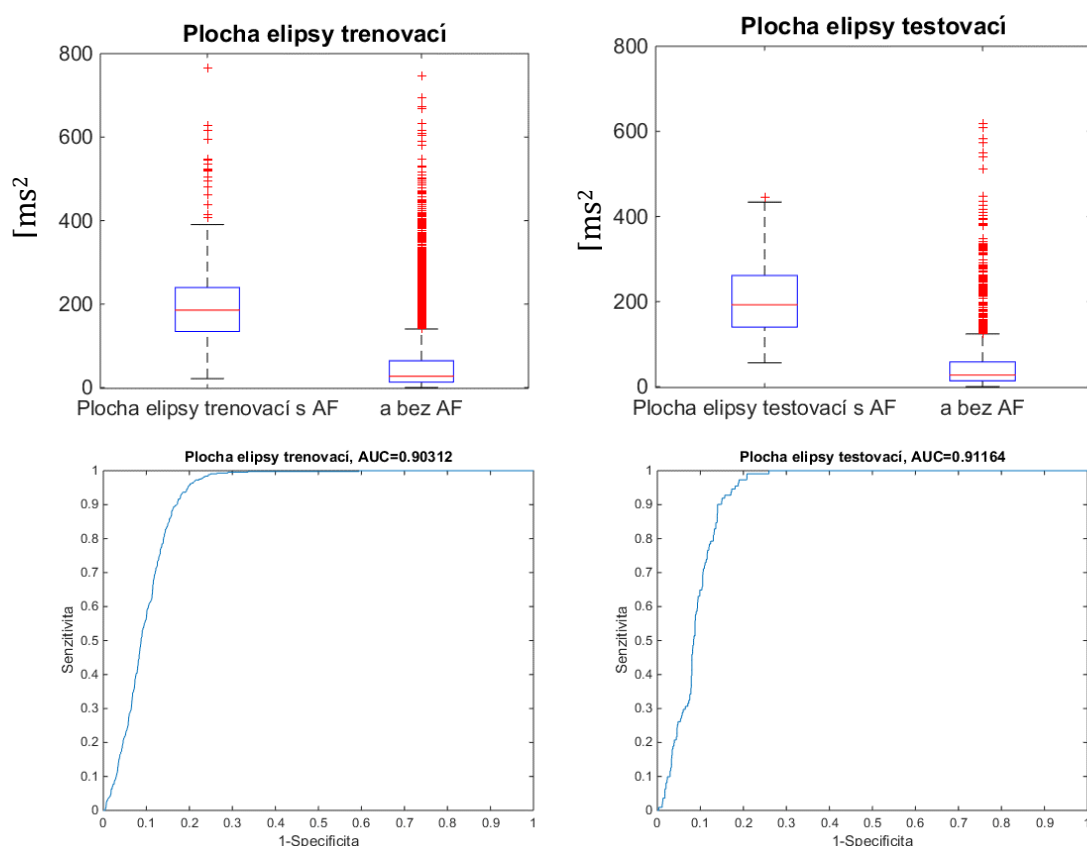
Další veličinou je směrodatná odchylka kolmá na diagonálu (SD 2). Box ploty pro tuto veličinu jsou zobrazeny na Obr. 10. Již na první pohled lze vidět jistou podobnost s odchylkou SD 1 až na malé rozdíly. U SD 2 můžeme pozorovat větší rozptyly u obou veličin, vzniká u nich i větší překryv. Po testování t-testem a Wilcoxonovým testem byla i pro směrodatnou odchylku SD 2 nulová hypotéza zamítnuta. To znamená, že i směrodatná odchylka ve směru kolmém na diagonálu je statisticky významná na hladině významnosti $\alpha=5\%$, a i na základě této směrodatné odchylky může být rozhodnuto, zda se u dat jedná o AF nebo ne. Podle ROC grafů ve spodní části Obr. 10 jde pak vidět, že rozlišovací schopnost SD 2 je podobná jako SD 1.



Obr. 10 Grafy SD 2: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

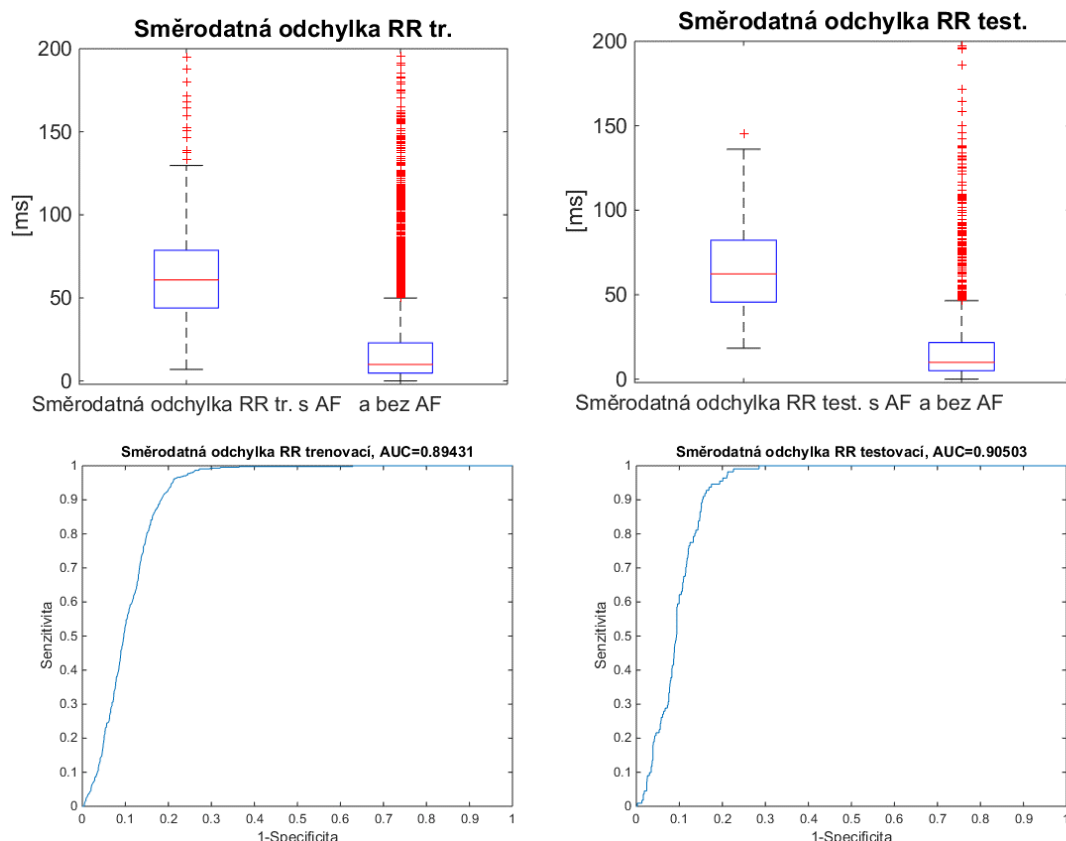
Z obou těchto odchylek se dá vypočítat plocha elipsy podle vzorce 2.4. Znovu jako v předchozích případech jsou zobrazeny box ploty na Obr. 11. Tyto Box ploty musely být upraveny, a to tak, že na ose y musely být pro viditelnost oříznuty na maximální hodnotu 800 [ms²] (dosahoval až 6000 pro odlehlé hodnoty). Jak je však

z těchto grafů vidět, dosahují skupiny již většího překryvu mezi daty. To se promítlo i na výsledné pravděpodobnosti t-testu a wilcoxonova testu, které byly o několik řádů vyšší než u SD 1 a SD 2, avšak stále byla nižší než hraničních 5 %. V důsledku toho byla tedy znovu zamítnuta nulová hypotéza a přijmula byla hypotéza alternativní. Takže i u plochy elipsy tvořené pomocí směrodatných odchylek SD 1 a SD 2 lze předpokládat statisticky významnou odlišnost středních hodnot výběrů s AF a bez AF. Z grafů ROC jde potom vidět, že hodnota AUC je mírně vyšší než u SD 1 a SD 2.



Obr. 11 Grafy plochy elipsy: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

O něco hůře pak vychází Směrodatná odchylka RR intervalů Obr. 12. Tato veličina se nepočítá z Poincarého plotu, ale vychází čistě z hodnot RR intervalů signálu. Na Obr. 12 potom můžeme vidět znovu dva box ploty pro tuto veličinu.

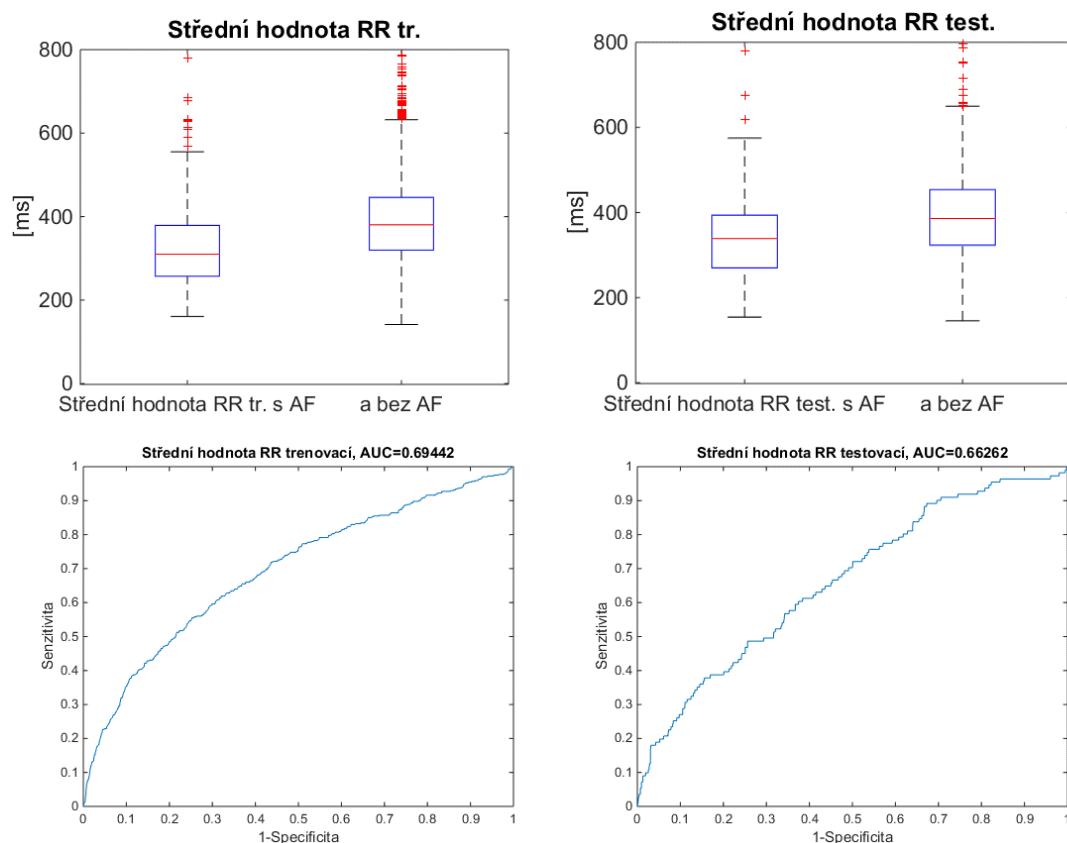


Obr. 12 Grafy Směrodatné odchylny RR: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Tyto boxploty byly znovu oříznuty z důvodu extrémních odlehlých hodnot, dosahujícím až k 1500 ms. Jak můžeme z grafů vyčíst, tyto skupiny se pro směrodatnou odchylnu intervalů R-R do velké míry překrývají, avšak mediány obou výběrů leží daleko od sebe. Výsledek t-testu i wilcoxonova testu nasvědčuje tomu, že ani tyto dvě rozložení nemají podobnou střední hodnotu (medián). Takže znovu zamítáme nulovou hypotézu.

Další testovanou veličinou je střední hodnota RR intervalů. Jak můžeme vidět na box plotech na Obr. 13 střední hodnota intervalu RR není pro detekci AF příliš vhodná. Již z těchto grafů lze vyčíst, že se hodnoty velmi překrývají, a téměř celá množina dat s AF spadá do rozmezí od minima po maximum hodnot bez AF. Po vypočítání t-testu a wilcoxonova testu však znovu nulovou hypotézu zamítáme. Takže i tento parametr je vhodný k další analýze i když z parametrů vhodných k rozlišení signálů vychází nejhůře. Z hodnot AUC potom můžeme vyčíst, že se blíží náhodnému rozdělení. Avšak pokud byla tato hodnota z klasifikace vynechána, klesla hodnota F1 measure až o 0.02. I když to není příliš velký pokles, zdá se že každá hodnota, která není náhodná a přináší do metody novou informaci, má vliv na zvýšení hodnoty přesnosti klasifikace. Toto tvrzení podkládá i literatura [20] v níž je řešena klasifikace signálů pomocí 75 hodnot spojených v jednu komplexní klasifikační metodu. Díky tomuto postupu byla celková přesnost podle hodnoty F1

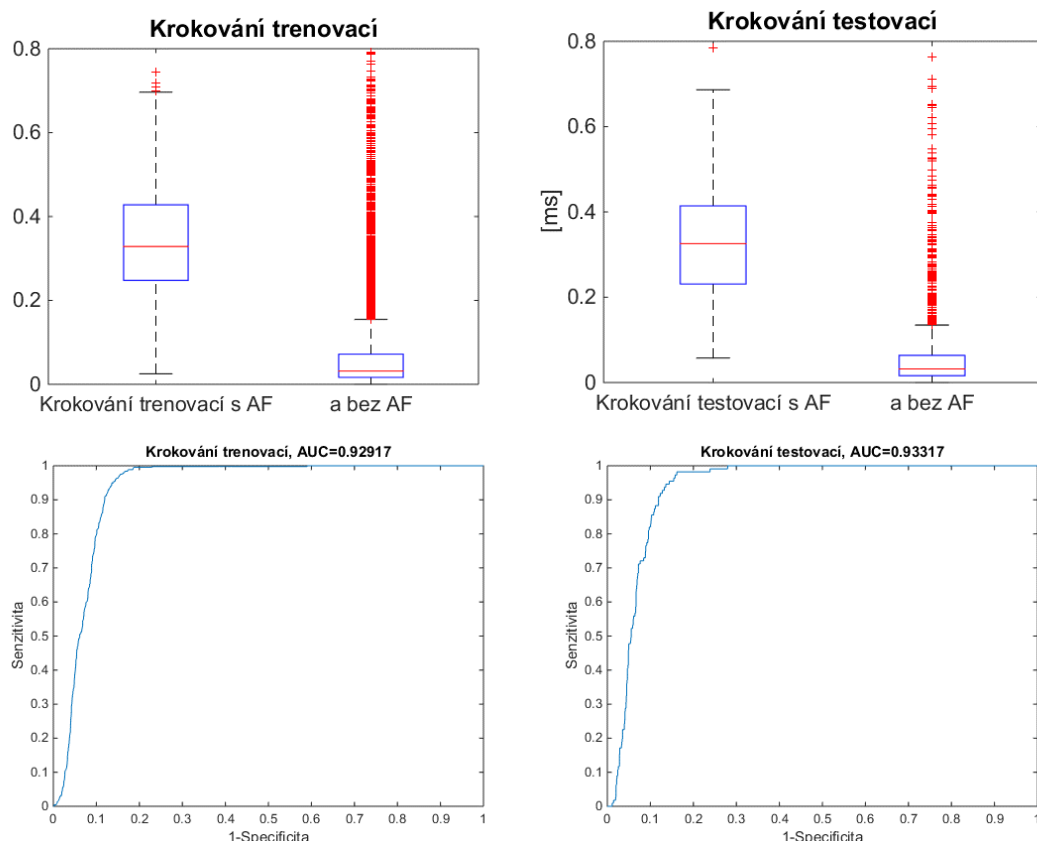
measure rovna 0.868. Je zde však také řešeno, že ani tato metoda měření kvality klasifikace nemusí být nejlepší. A tohoto výsledku bylo docíleno právě ve zpětné vazbě na hodnotu F_1 measure.



Obr. 13 Grafy střední hodnoty RR: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Nejlépe ze všech potom dopadlo krokování. Tato hodnota udává průměrný nárůst vzdáleností dvou bodů a je dopočítána podle vzorce 2.5 [6]. Její box ploty jsou zobrazeny na Obr. 14. Tento graf musel být znovu oříznut. Lze na něm vidět, že i přes to, že extrémně odlehlé hodnoty signálů bez AF leží v rozmezí signálů s AF, jsou si mediány dat velmi vzdálené a ani kvartily se zde nepřekrývají. Po dopočítání t-testu a wilcoxonova nám dle předpokladu vyšlo zamítnutí nulové hypotézy a přijetí alternativní. Z grafů ROC jde potom vidět, že samotná klasifikace na základě této hodnoty by dokázala v celku přesně rozdělit skupiny pacientů. Hodnota AUC je zde až 0,93. To je 0.1 více než u předchozí nejlepší hodnoty, ale pořád je to o 0,5 méně než u celkové klasifikace pomocí neuronové sítě.

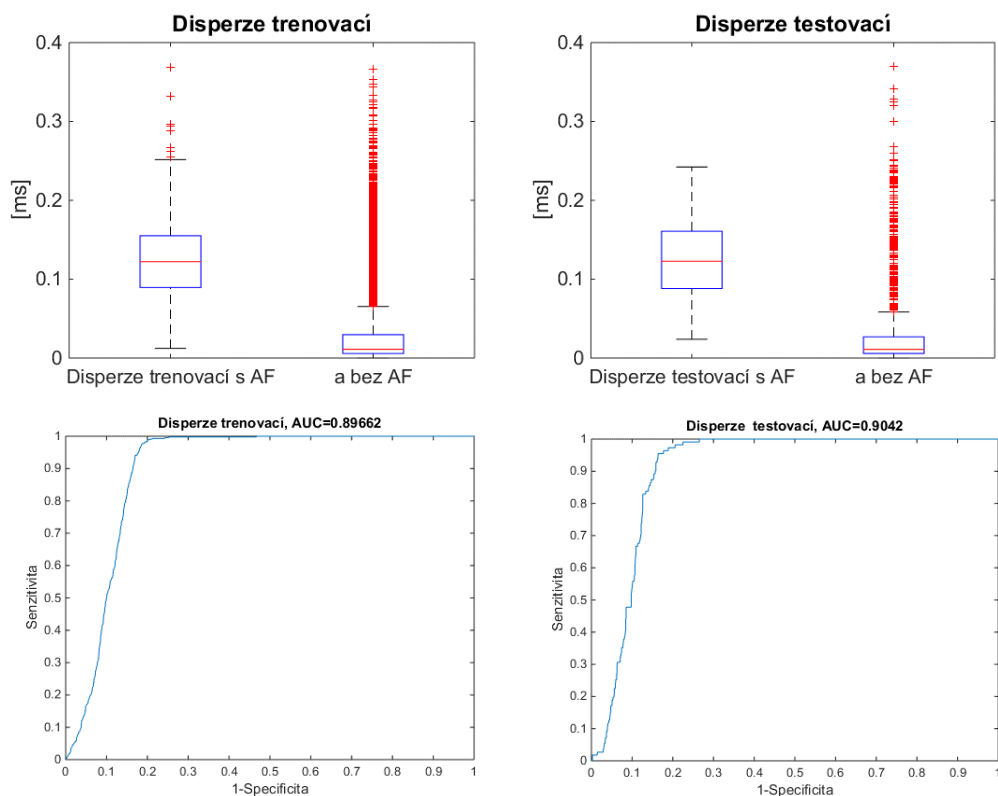
Posledním případem je potom rozptyl. Tento rozptyl (podle vzorce 2.6) není počítaný pouze z intervalů RR, ale počítá s body v Poincarého plotu. Pomocí derivace určíme střed grafu a počítáme průměrný rozptyl bodů oproti tomuto středu [5].



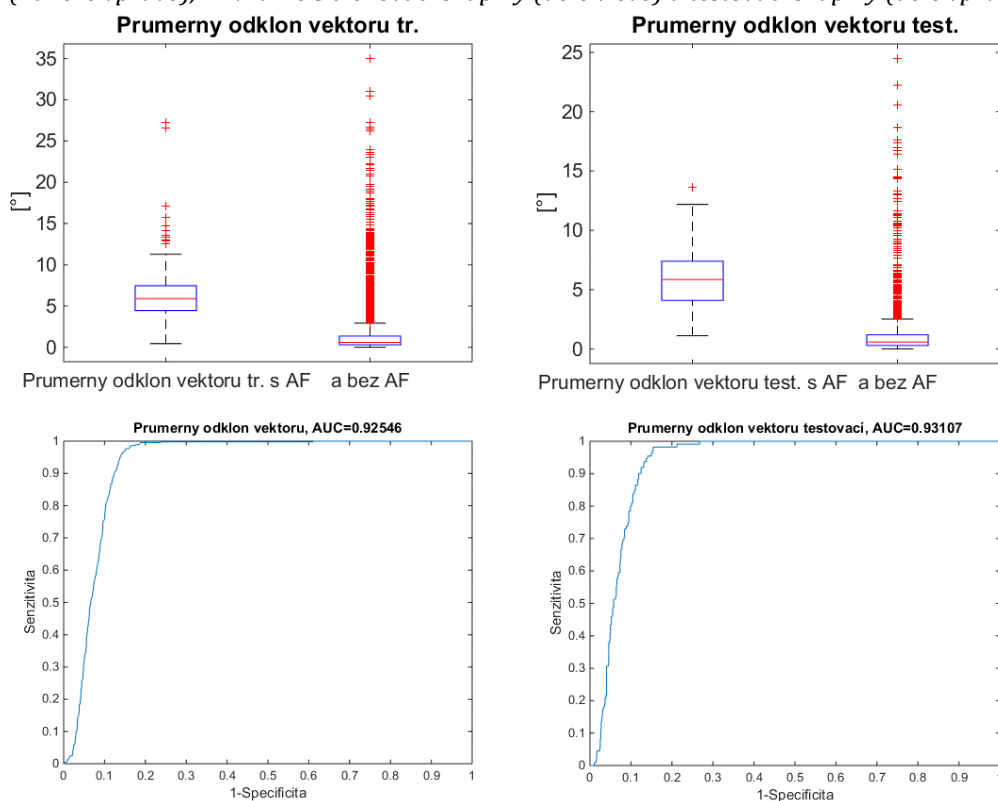
Obr. 14 Grafy krokování (stepping): Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

I tato veličina vychází velmi dobře. I přesto že se grafy rozptylu bodů (Obr. 15) velmi podobají grafům krokování, rozptyl obou skupin je menší než u krokování. Ale hodnoty AUC jsou o málo menší. Jak už jde z grafů vidět, byla i nulová hypotéza o shodě středních hodnot (mediánů) je zamítnuta jak u t-testu tak u testu wilcoxonova. Přijímáme tedy znovu alternativní hypotézu a zařadíme i rozptyl do skupiny pro trénování klasifikačních programů.

Předposlední hodnotou je potom veličina VAI. Tato hodnota se podle grafů na Obr. 16 řadí mezi nejlepší. Z boxplotů jde vyčíst, že medián pacientů s AF leží až nad hranicí 5°, to znamená že více než půlka dat s AF má hodnotu VAI větší než 5° zatímco medián horní kvartil dat bez AF leží pod touto hranicí. To znamená že více než tři čtvrtiny dat s AF jsou pod tímto prahem. Už z tohoto výroku lze předpokládat správnou klasifikaci což jen podkládá hodnota AUC, která je téměř stejná jako u krokování. Tvrzení podkládají znovu i statistické testy, které zamítají nulovou hypotézu a potvrzují tak statistickou významnost i této veličiny

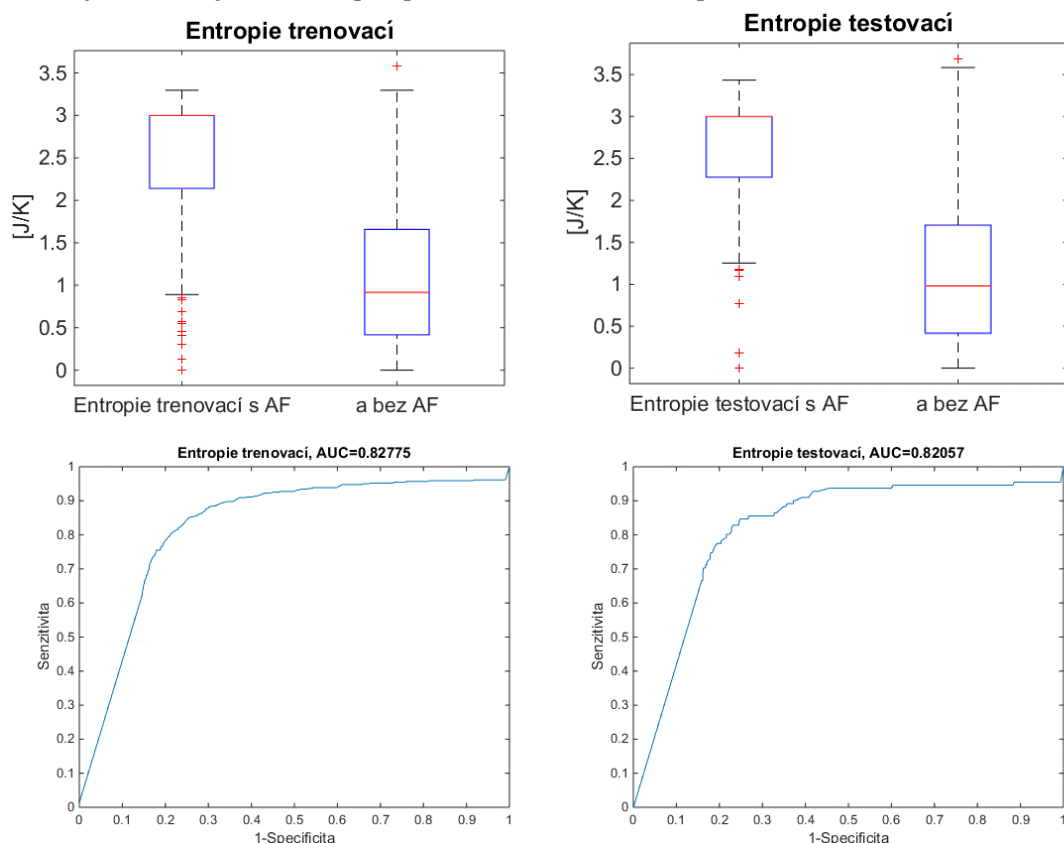


Obr. 15 Grafy rozptylu (dispersion): Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)



Obr. 16 Grafy VAI: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

Poslední veličinou, která vstupuje do výpočtu, je Entropie signálu. I přesto, že tato hodnota měla být původně nejlepší v klasifikaci signálů, tak se i přes všechnu snahu nepodařilo doladit její nastavení k hodnotám lepším, než je na Obr. 17. I přesto že boxploty vypadají jako že se obě skupiny zcela překrývají, jdou vidět velmi rozdílné mediány. To znamená že tato veličina sice nerozděluje signál dobře, ale nese jistou informaci. Statistickými testy bylo znovu rozhodnuto o statistické významnosti této veličiny. Proto byla i entropie použita ke klasifikaci pomocí neuronové sítě.




Obr. 17 Grafy Entropie: Boxplot trénovací skupiny (nahore vlevo) a testovací skupiny (nahore vpravo), křivka ROC trénovací skupiny (dole vlevo) a testovací skupiny (dole vpravo)

3.3 Výsledky klasifikace EKG záznamů pomocí dopředné neuronové sítě

Nejdůležitějším bodem je potom výběr a nastavení vlastností neuronové sítě. Nejjednodušší sítí je tedy perceptron, u kterého však nepředpokládáme velkou přesnost rozdělení modelu. V praxi potom vychází přesnost podle trénovací množiny podle Tab. 1. Z této tabulky jde poznat že ani 5fold validace trénovací množiny nevychází příliš dobře. I přesto že jsou zde odlehle hodnoty, což lze přisoudit tomu, že kvůli dlouhému trénování perceptronu byla omezena trénovací doba pouze na 10 epoch. Perceptron však již po několika epochách učení dosáhnul MSE (mean squared error, čtverec průměrné chyby) kolem 0,1, ale níže už ani při více epochách neklesnul. Maximum validačních chyb jsme ponechali nastaveno na 5. Grafický náhled perceptronu je potom vidět na Obr. 18, je zde vidět že jako vstup je použito všech 9 příznaků každému je pro první epochu přiřazena náhodné váhy a bias. V dalším kroku stejné epochy jsou potom upraveny hodnoty vah a biasu podle cyklického pravidla, kdy se podle výsledku jedné epochy a aktivace neuronů upraví váhy v následující epoše. Výstupem je potom „Hard limit“ jež přiřadí výsledku buď hodnotu 1 nebo 0.

TAB. 1 VÝSLEDKY PRO PERCEPTRON

TRÉNOVACÍ 5FOLD VALIDACE	F1 Measure [%]	Specificita [%]	Senzitivita [%]
1	89,2	83,6	95,6
2	81,6	91,7	71,2
3	90,0	83,3	97,8
4	89,3	80,2	99,6
5	91,1	84,9	97,8
PRŮMĚR	88,2	84,7	92,4
STD	3,77	4,25	11,9
TESTOVACÍ	73,5	85,9	97,3



Obr. 18 Znáznornění použitého perceptronu

Protože i podle výsledků není perceptron vhodným řešením pro tento problém je třeba použít složitější neuronovou síť. Vhodnou volbou se zdá být vícevrstvá


neuronová síť s učením pomocí zpětného šíření chyby a výpočtem pomocí gradientu (derivace chybové funkce). Gradient určuje směr a velikost posunu v dalším kroku učení. Pro začátek vybereme učení pomocí Lavenberg-Marquardt v aplikaci matlab pomocí funkce *trainlm*. Toto nastavení se vyznačuje jednoduchostí a rychlostí učení, kvůli absenci nutnosti výpočtu Hessovy matice nahrazeného aproximací z jakobiánu matice. Toto nastavení je schopné se naučit jen v několika desítkách epoch, takže nepovažuji za nutné omezovat délku výpočtu či počet epoch (ponecháno 1000 epoch). Důležité je u těchto sítí především nastavení počtu neuronů ve vnitřní vrstvě. K otestování ideálního počtu těchto neuronů potom slouží funkce *odladi.m*, která mění počet neuronů ve vnitřní vrstvě od 1 do 50. Funkcí vnitřních neuronů je sigmoida. Ta nepřihadí výstupu neuronu hodnotu 1 nebo 0, ale přiřadí hodnoty z intervalu [0, 1] takže je výstup funkce spojitý. Neuron v poslední výstupní vrstvě potom spojí všechny předešlé výstupy pomocí jednotlivých vah do jedné spojitě výstupní funkce v rozsahu [0, 1]. V dalším kroku je však potřeba data rozdělit do dvou skupin. O to se postará aplikace *rozlisovaci_schopnost.m*. Ta sestrojí ROC křivku a vyhledá nejlepší práh pomocí vzorce 3.1 který je součástí vnitřní funkce *perfcurve.m*. Kde $cost(P|N)$ je cena přiřazení N do P a kde $P=TP+FN$ a $N=TN+FP$.

$$S = \frac{cost(P|N) - cost(N|N)}{cost(N|P) - cost(P|P)} \cdot \frac{N}{P} \quad 3.1$$

Další možností je metoda učení Bayesovou regulací, ta počítá s pravděpodobností při zpětném šíření chyby. Je složitější pro výpočet takže učení sítě je potřeba omezit jak časově tak počtem epoch. Protože bez omezení se síť stále učí. Čas učení je tedy omezen maximálně na 3 minuty a na 500 epoch, navíc je síť považována za naučenou pokud $MSE < 0,03$. Navíc u této metody přibývá parametr rychlosti učení, který se v průběhu učení mění, a buďto krok zvětšuje, nebo zmenšuje, v závislosti na vzdálenosti od lokálního minima se potom buď násobí 10 anebo 0,1. Počáteční velikost parametru je ponechána na 0,05.


K porovnání těchto dvou metod Potom slouží tabulky z přílohy znázorněné na grafu na Obr. 19. Na grafu jde vidět průměrná hodnota z 5 opakovaných učení 5fold validace pro počet neuronů ve skryté vrstvě sítě od 1 do 50. Pro všechny hodnoty je znázorněn i rozptyl v těchto 5 učeních který znázorňuje stabilitu učení sítě. Na první pohled je tedy Bayesova metoda lepší. Nejen že dosahuje o 1,3 % vyšší hodnotu už pro 15 neuronů, ale celkově je její přesnost vyšší. Lavenberg-Marquardt metoda (LM metoda) je však výrazně stabilnější (má menší rozptyl hodnot). Když ale bereme v potaz nejhorší naučení Bayesovy sítě je hodnota F1 measure lepší, než v nejlepším případě LM metody. Bayesova metoda má však uvnitř programu menší rozptyl v metodě 5fold validace až dvojnásobně. To znamená, že v rámci učení na jedné skupině trénovacích dat rozdělené na 5 skupin dosahuje lepší stability učení než u metody LM. Z těchto hodnot tedy usuzujeme, podle předpokladu, že je nejvhodnější nejjednodušší síť s nejlepšími výsledky, že nejlepší volbou by byla

Bayesova metoda s 23 neurony uvnitř skryté vrstvy, neboť dosahuje vysoké hodnoty F1 measure = 95,91 % a směrodatná odchylka hodnot je v okolí nejmenší $\text{std}=0,27$ %. Pro porovnání potom vybereme příklad z LM metody s 17 neurony ve skryté vrstvě, který dosahuje hodnoty F1 measure 94,49 % a rozptyl hodnot je $\text{std}=0,09$ %.



Obr. 19 Graf průměrů F1 measure trénovacích množin s odchylkou v 5 opakováních

Schéma obou neuronových sítí je potom stejné jako na Obr. 20. Liší se pouze formou výpočtu vah sítě. V Tab. 2 a Tab. 3 lze potom vidět výsledky učení metodou LM (17 neuronů) a Bayes (23 neuronů), kde jsou hodnoty 5fold pro každou z 5 variant rozložení testovacích a validačních dat, specificity těchto skupin a senzitivity. Z nich je vypočítán průměr a směrodatná odchylka. Právě tento průměr a směrodatná odchylka jsou z 5 opakovaných trénování zprůměrována pro různá množství neuronů grafu na Obr. 19. Protože takovýto objem dat zpracovává program velmi dlouho, musíme se spokojit s pouhými 5 opakováními celého cyklu učení a testování pro výběr ideálního počtu neuronů. Pro vybraná množství neuronů potom zopakujeme celý proces učení a testování celkem 20krát a průměrné výsledky tohoto opakování jsou znázorněny v Tab. 4



Obr. 20 Schéma vícevrstevných neuronových sítí s X skrytými neurony

TAB. 2 VÝSLEDKY PRO LAVENBERG-MARQUARDT

TRÉNOVACÍ 5FOLD VALIDACE	F1 Measure [%]	Specificita [%]	Senzitivita [%]
1	94,9	92,0	98,0
2	93,7	89,1	98,8
3	95,1	92,9	97,5
4	93,5	90,2	97,4
5	94,8	93,2	96,8
PRŮMĚR	94,4	91,5	97,7
STD	0,74	1,79	0,76
TESTOVACÍ	83,7	94,13	91,0

Pokud se blíže zaměříme na Tab. 2 lze pozorovat, že specifická na testovací skupině je dokonce vyšší než na skupině trénovací, avšak senzitivita je naopak o hodně nižší (6,7 %). Důvodem může být to, že práh dělící trénovací skupinu nemusí stejně dobře dělit i testovací skupinu. Z Tab. 3 lze vyčíst, že ačkoliv F1 measure pro 5fold validaci vychází o 1,7 % lépe než u LM metody jsou její výsledky na testovací skupině horší. Dokonce i odchylka je u Bayesovy metody menší. Příčinou tohoto problému může být různé rozložení hodnot v trénovací a testovací skupině. Pokud jsou tyto dvě skupiny rozdílné, může dojít k výsledku který, ačkoliv se na trénovací množině potvrdil i metodu křížové validace, neodpovídá předpokladům. To proto, že trénovací množina by měla být velmi podobná množině testovací.

TAB. 3 VÝSLEDKY PRO BAYESOVU REGULACI

TRÉNOVACÍ 5FOLD VALIDACE	F1 Measure [%]	Specificita [%]	Senzitivita [%]
1	96,1	94,1	98,5
2	96,0	93,9	98,3
3	96,5	94,0	99,3
4	96,0	94,1	98,3
5	96,0	93,2	98,9
PRŮMĚR	96,1	93,85	98,7
STD	0,22	0,36	0,44
TESTOVACÍ	82,7	93,8	89,2

Jeden výsledek uvedený v těchto tabulkách však může být způsoben z části náhodou proto je nutné brát v potaz i průměrné výsledky u těchto nastavení jako jsou v Tab. 4.


TAB 4. ZPRŮMĚROVANÉ VÝSLEDKY 20 CYKLŮ UČENÍ

BAYESOVA METODA 23 NEURONŮ				
Train F1 [%]	Train std [%]	Test F1 [%]	Test senz. [%]	Test spec. [%]
96,07	0,469	83,64	88,11	94,51
LM METODA 17 NEURONŮ				
Train F1 [%]	Train std [%]	Test F1 [%]	Test senz. [%]	Test spec. [%]
94,38	0,651	82,28	91,58	93,17


Z Tab. 4 lze vyčíst, že Bayesova metoda má nižší senzitivitu u testovací skupiny, jinak však vychází obě metody přibližně stejně. Vyšší specificita testu však znamená menší počet chyb typu I. Protože je v testovací skupině mnohem více signálů bez AF (90 %) je důležité, pro menší chybovost, minimalizovat především chyby typu I. Proto je hodnota F1 vyšší právě u metody Bayesovy, a proto jsem pro řešení zvolil právě tuto metodu s 23 neurony ve vnitřní vrstvě. Tato tabulka je průměrem z tabulek které jsou k náhledu v příloze.

Pro přehled můžeme klasifikovaná data zobrazit i jako grafy, do kterých vyneseme závislosti mezi jednotlivými číselnými reprezentacemi signálu. To proto, aby byla eliminována závislost na pozici vzorku mezi ostatními. Na Obr. 20 můžeme vidět graf závislosti SD 1 a SD 2, červené body jsou pacienti, kteří byli v testovací skupině detekováni špatně. Zelené body jsou pacienti trpící atriální fibrilací detekovaní pomocí neuronových sítí správně. A modré body jsou pacienti, kteří jsou zdraví a byly detektorem určeny jako pacienti netrpící atriální fibrilací. Z grafu lze vyčíst, že pod prahovou hodnotou SD 1 i SD 2 = 5 ms leží jen málo pacientů se síňovou fibrilací, nad hodnotou 6,5 ms naopak leží jejich většina. Z Obr. 20 jde potom poznat jaké signály určila metoda neuronových sítí za postižené síňovou fibrilací.

Dalšími vhodnými grafy jsou pak závislosti pro zobrazení jsou potom závislost rozptylu na krokování [5] (Obr. 21) a závislost průměrné hodnoty RR na směrodatné odchylce RR (Obr. 22). Graf však jen přehledněji znázorňuje to, co lze vyčíst i z box plotu. Důležitější jsou pro nás barevné odlišení, z nichž lze vyčíst, jaké množství bodů je označeno špatně (červené), jaké množství správně jako signály s AF (zelené), a jaké množství správně jako signály bez AF (modré).




Obr. 21 Závislost Směrodatné odchylky SD 2 [ms] na odchylce SD 1 [ms] detekované doktorem a pomocí funkce neuronových sítí v prostředí matlab (zelené – TP, modré – TN, červené – F)




Obr. 22 Závislost rozptylu [ms] na krokování [ms] detekované doktorem a pomocí funkce neuronových sítí v prostředí matlab (zelené – TP, modré – TN, červené – F)

Dalším grafem pro znázornění je graf závislosti průměrné hodnoty RR na směrodatné odchylce (Obr. 22).



Obr. 23 Závislost průměrného RR [ms] na směrodatné odchylce RR [ms] detekované doktorem a pomocí funkce neuronových sítí v prostředí matlab (zelené – TP, modré – TN, červené – F)

A posledním grafem je pak závislost entropie na VAI (Obr. 23). Entropie však dosahuje kvůli výpočtu v programu *matlab* hodnot Inf (nekonečna) pro poměr shod 1/0, NaN (neurčeno) pro poměr shod 0/0 a $-Inf$ (-nekonečno) pro poměr shod 0/1. Tyto hodnoty jsou ověřeny vnitřní funkcí při výpočtu entropie a jsou nastaveny tak aby odpovídaly realitě, ale zanáší do grafu určité zkreslení.



Obr. 24 Závislost Entropie [J/K] na VAI [°] detekované doktorem a pomocí funkce neuronových sítí v prostředí matlab (zelené – TP, modré – TN, červené – F)


Na těchto grafech můžeme vidět závislost pozitivity či negativity AF na pozici, respektive na jednotlivých hodnotách, v grafu. Důležité je, že vstupem do neuronové sítě je všech 9 původních hodnot pro každý signál, v její skryté vrstvě je potom 17 neuronů a výstupem je hodnota v rozmezí od 0 do 1. Signály na trénování a testování

jsou vybrány předem, a i když se jejich pořadí mění uvnitř jednotlivých skupin nikdy nedochází k promíchání signálů těchto dvou skupin. Do testovací skupiny bylo potom vybráno 1247 (90 %) signálů bez AF a 111 (10 %) s AF. Z těchto signálů potom právě jeden vybraný cyklus udělal celkem 89 (6,6 %) chyb. Z těchto chyb je 83 signálů určeno jako falešně pozitivních (FP) a pouze 6 signálů je určeno jako falešně negativních (FN). Vybraná senzitivita potom dosahuje 95 %, specificita 93 % a hodnota F1 measure 83 %.

4 ZÁVĚR

Nejprve bylo graficky a statistickou metodou pomocí nepárového t-testu ověřena správnost jednotlivých klasifikací (SD 1, SD 2, plocha elipsy, krokování, rozptyl, střední hodnota RR intervalů, směrodatná odchylka RR intervalů, VAI a entropie). Přičemž všechny tyto veličiny se ukázaly jako statisticky významné pro detekci síňových fibrilací, a to dokonce na hladině významnosti $\alpha=0,01$ %.


Dále byla provedena detekce pomocí dopředné neuronové sítě, na základě níž jsou data z testovací skupiny rozděleny na dvě skupiny. První skupinou jsou data, u kterých byla detekována AF a druhou data u kterých ne. Tato metoda by se dala nahradit například tvrdým prahem nebo rozhodovacím stromem.



Obr. 25 ROC trénovací skupiny dat (AUC = 0.98)

S neuronovou sítí bylo dosaženo senzitivity 95 % a specifickosti 93 %. To znamená že pouze 95 ze 100 pacientů trpících síňovou fibrilací, je označeno za nemocné, a 93 ze 100 zdravých pacientů je označeno jako zdravý. To ale znamená, že u 5 pacientů ze 100 by nebyla nemoc odhalena, a u 7 pacientů ze 100 by byla určena nemoc, kterou netrpí. ROC z Obr. 24 potom ukazuje, že plocha pod křivkou je pro trénovací množinu vysoká (AUC = 0,980) a pro testovací množinu (Obr. 25) nižší (AUC = 0,957). Takováto klasifikace není dokonalá, avšak je méně chybová než jiné nastavení. Pomocí rozhodovacího prahu se dá výstup neuronové sítě nastavit i jinak. Ale počet celkových chyb se tím pouze zvýší (snížením TN se zvýší FP a naopak). Nevýhodou učení neuronových sítí je to, že se jedná částečně o náhodný proces, při kterém se mohou výsledky učení lišit i pokud se vstup nijak nezmění. Důvodem je, že neuronové sítě patří mezi stochastické procesy, které jsou velmi citlivé na své vstupní nastavení. Dochází u nich k náhodnému prohledávání prostoru, a proto

nemusíme při špatném nastavení na globální řešení narazit. Chyby klasifikace se při opakovaných pokusech pohybují kolem 71. Chyby 2. typu (FN) jsou závažnější a pohybují se okolo 13. Což je poměrně velká část ze 111 celkových signálů. Chyby 1. typu (FP) se pak pohybují okolo 68 chyb. V součtu je chyb vždy podobně, takže čím více chyb 1. typu tím méně chyb 2. typu a naopak. Pro nás je však lepší více chyb 1. typu, navíc jejich poměr proti celkovým 1247 signálům bude vždy menší.



Obr. 26 ROC testovací skupiny dat (AUC = 0.957)

Při porovnání s výsledky soutěže „PhysioNet/Computing in Cardiology Challenge 2017” [20] bylo dosaženo srovnatelných výsledků. Uvedených v tabulce:


TVŮRCE	F ₁ TESTOVACÍ	F ₁ TRÉNOVACÍ
TATO PRÁCE	0,836	0,960
TEIJEIRO A SPOL.	0,831	0,990
DATTA A SPOL.	0,826	0,968
ZAHIBI A SPOL.	0,825	0,990
HONG A SPOL.	0,822	0,859

Při porovnání s výsledky diplomové práce na obdobné téma [27]

Tvůrce	F1 measure [%]	Senzitivita [%]	Specifická [%]
Tato práce	83,6	88,1	94,5
Práce [27]	66,8	67,1	97,0

Pro přehled výsledků i pro ostatní nastavení těchto dvou typů sítí jsou sestaveny grafy na Obr. 27 kde jsou zobrazeny hodnoty F1 measure v závislosti na počtu neuronů v neuronové síti, u každé hodnoty je znázorněna i odchylka v rámci 5

opakování. Z tabulky výsledků 1 a 2 z příloh. Z tohoto grafu lze vyčíst, že Bayesova metoda má na testovací sadě dat lepší výsledky. Do 15 neuronů ve skryté vrstvě sítě hodnota F1 measure postupně stoupá, není přeučená na trénovací data. Ale u složitějších sítí (nad 20 neuronů) jde poznat pokles hodnoty. To znamená, že ideální je podle výsledků Bayesova metoda se 14 neurony ve skryté vnitřní vrstvě. LM metoda je však stabilnější a její výsledky mají menší odchylky. Je však pravidlem, že testovací data neslouží k nastavování sítě pouze k jejímu otestování. Pokud bychom upravily cyklus na tuto hodnotu, vycházel by lépe, ale pouze na datech z testovací skupiny a nemuselo by tomu tak být u nových dat v praxi. Počáteční nastavení vah sítě je vybíráno náhodně, takže nemusí být vždy nalezeno globální minimum, nebo nemusí být nalezeno ani stejné lokální minimum. Tato chyba by mohla být eliminována například pevným nastavením počátečních vah systému pro všechny učení.



Obr. 27 Hodnoty F1 measure pro Bayesovu a LM metodu (1 až 50 neuronů)

Ačkoliv výsledek diplomové práce není dokonalý a obnáší nemalé klasifikační chyby, dá se považovat za úspěšný a poměrně přínosný. V praxi může být užitečný při klasifikaci, avšak nemůže nahradit přesnost zkušeného zdravotnického personálu.

LITERATURA

- [1] ŠTEJFA, M. ŠUMBERA, J. BRAVENÝ, P. Základy elektrokardiografie, Brno: Masarykova univerzita, fakulta lékařská, 1991, 147 s. ISBN 80-210-0265-4.
- [2] AUTOR NEZNÁMÝ. Stavba srdce – obrázek. Třídní stránky. [online]. 29.11.2014 [cit. 2018-11-29]. Dostupné z: <http://gymplmb.blogspot.cz/2013/01/obrazek.html>
- [3] BRAGARD, J. Universidad de Navara [online]. 2010 [cit. 2019-05-24]. Analysis of time series of physiological data. Upravené a dostupné z: <http://fisica.unav.es/~jbragard/detailecg.gif>
- [4] KOZUMPLÍK J.: Multitaktní systémy. Elektronické skriptum UBMI FEKT VUTBR 2005, dostupné z: https://www.feec.vutbr.cz/et/skripta/ubmi/Multitaktni_systemy_S.pdf
- [5] TAYEL, Mazhar B. a Eslam I. ALSABA. Poincaré Plot for Heart Rate Variability. International Journal of Biomedical and Biological Engineering [online]. World Academy of Science, Engineering and Technology, 2015, 9(9), 4 [cit. 2019-01-04]. DOI:10.1999/1307-6892/10002615. Dostupné z: <https://waset.org/publication/Poincaré-Plot-for-Heart-Rate-Variability/10002615>
- [6] JINHO, Park, Lee SANGWOOK a Jeon MOONGU. Atrial fibrillation detection by heart rate variability in Poincare plot. BioMedical Engineering OnLine [online]. © Park et al; licensee BioMed Central Ltd. 2009, 2009, 11 prosinec 2009, 12 [cit. 2019-01-04]. Dostupné z: <https://doi.org/10.1186/1475-925X-8-38>
- [7] PISKORSKI, Jarosław a Przemysław GUZIK. Filtering Poincaré plots. COMPUTATIONAL METHODS IN SCIENCE AND TECHNOLOGY [online]. Institute of Physics, University of Zielona Góra, Poland; Department of Cardiology – Intensive Therapy, University of Medical Sciences in Poznań, Poznań, Poland, 2005, 11(1) (39-48(2005)), 10 [cit. 2019-01-04]. DOI: DOI:10.12921/cmst.2005.11.01.39-48. Dostupné z: http://cmst.eu/wp-content/uploads/files/10.12921_cmst.2005.11.01.39-48_Piskorski.pdf
- [8] Ruan, X., Liu, C., Liu, C., Wang, X., & Li, P. (2011). Automatic detection of atrial fibrillation using R-R interval signal. 2011 4th International Conference on Biomedical Engineering and Informatics (BMEI), 644–647. Dostupné z: https://www.researchgate.net/publication/220715249_Automatic_detection_of_a_atrial_fibrillation_using_R-R_interval_signal
- [9] Co to je entropie. Www.tzb-info.cz [online]. 2002 [cit. 2019-11-04]. Dostupné z: <http://www.tzb-info.cz/925-co-to-je-entropie>
- [10] Neznámý. (n.d.). 2.Teorie informace 2.1 Vznik a vývoj teorie informace. Dostupné z: http://www.uai.fme.vutbr.cz/~matousek/TIK/dokumenty/osmera_kap2.pdf

- [11] Travis J Moss, D. E. L., & Moorman, J. R. (2014). Physiological Measurement Local dynamics of heart rate: detection and prognostic implications Related content. Dostupné z: <https://pdfs.semanticscholar.org/426a/19f2871ba3fe5f2f3d427491f16330be59b2.pdf>
- [12] Lake, D. E., & Moorman, J. R. (2011). Accurate estimation of entropy in very short physiological time series: the problem of atrial fibrillation detection in implanted ventricular devices. *American Journal of Physiology-Heart and Circulatory Physiology*, 300(1), H319–H325. Dostupné z: https://www.researchgate.net/publication/47635928_Accurate_estimation_of_entropy_in_very_short_physiological_time_series_The_problem_of_atrial_fibrillation_detection_in_implanted_ventricular_devices/download
- [14] Alcaraz, R., Abásolo, D., Hornero, R., & Rieta, J. J. (2010). Optimal parameters study for sample entropy-based atrial fibrillation organization analysis. *Computer Methods and Programs in Biomedicine*, 99(1), 124–132. Dostupné z: <https://vdocuments.site/optimal-parameters-study-for-sample-entropy-based-atrial-fibrillation-organization.html>
- [15] Holčík, J., Analýza a klasifikace signálů. Nakladatelství VUT v Brně, Brno (1992)
- [16] Kotek, Z., Brůha, I., Chalupa, V., Jelínek, J., Adaptivní a učící se systémy. SNTL, Praha (1980)
- [17] Pavlík, J. (2005). Aplikovaná statistika, 173, Retrieved from http://147.33.74.135/knihy/uid_isbn-80-7080-569-2/pages-img/001.html
- [18] Veterinární a farmaceutická fakulta, B. (n.d.). Parametrické testy – Studentův t-test. Použito 14. dubna 2019, z teorie, přednáška 3, Dostupné z: <https://cit.vfu.cz/statpotr/POTR/Teorie/Predn3/ttest.htm>
- [19] Masarykova univerzita, B. (2014). Analýza dat pro Neurovědy. Dostupné z: https://is.muni.cz/el/1411/jaro2014/DSAN01/um/45910621/Analiza_dat_pro_Neurovedy_-_blok_6.pdf
- [20] Clifford, G. D., Liu, C., Moody, B., Lehman, L. H., Silva, I., Li, Q., ... Mark, R. G. (2017). AF Classification from a Short Single Lead ECG Recording: the PhysioNet/Computing in Cardiology Challenge 2017. *Computing in Cardiology*, 44. Dostupné z: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5978770/>
- [21] MATLAB - MathWorks - MATLAB & Simulink.[Online] Použito Květen 8, 2019, z <https://uk.mathworks.com/products/matlab.html>
- [22] Wolfram Mathematica: Documentation center, [Online], <http://reference.wolfram.com/applications/neuralnetworks/NeuralNetworkTheory/2.5.3.html>
- [23] Eva Volná. (2008). SKRIPTA NEURONOVÉ SÍTĚ 1. [online] Dostupné z http://www1.osu.cz/~volna/Neuronove_site_skripta.pdf

- [24] DAVID POOLE, Alan Mackworth, nedatováno. Cross Validation, Artificial intelligence. *Foundation of computational agents* [online] [vid. 2019-08-02]. Dostupné z: https://artint.info/html/ArtInt_189.html
- [25] JASON BROWNLEE, 2018. A Gentle Introduction to k-fold Cross-Validation. *Machinelearning mastery* [online] [vid. 2019-08-02]. Dostupné z: <https://machinelearningmastery.com/k-fold-cross-validation/?fbclid=IwAR1O0xZKzlOGkp1FgnhmVcp-3AE831owT4GivZWQWEy9JzN0QVluLf0OwCY>
- [26] Komprdová, K. 2012. Rozhodovací stromy a lesy. [online] [vid. 2019-08-02]. Dostupné z <https://www.iba.muni.cz/res/file/ucebnice/komprdova-rozhodovaci-stromy-lesy.pdf>
- [27] Ing. Ambrožová, M. (2019). DETEKCE FIBRILACE SÍNÍ V KRÁTKODOBÝCH EKG ZÁZNAMECH. [online] Dostupné z: https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=190966

Seznam symbolů, veličin a zkratek

AF	-	Síňová (atriální) fibrilace
AUC	-	Plocha pod křivkou (Area under curve)
EKG	-	Elektrokardiogram (Elektrokardiograf)
FEKT	-	Fakulta elektrotechniky a komunikačních technologií
FP	-	Špatně pozitivní (False Positive)
FN	-	Špatně negativní (False Negative)
VUT	-	Vysoké učení technické v Brně
R-R	-	Interval od R vlny k R vlně
ROC	-	Regresivní operativní křivka (Regresive operative curve)
SD	-	Směrodatná odchylka (Standart Deviation)
TP	-	Správně pozitivní (True Positive)
TN	-	Správně negativní (True Negative)
Std	-	Odchylka (standart deviation)

Seznam příloh

Příloha 1. CD

Obsah CD:

- Project_BTL.m
- rozlisovaci_schopnost.m
- boxploty.m
- sampleEntropy.m
- odladeni.m
- grsSave

- BTL_qrs.mat
- indAfibTrainTest.mat
- mainCategories.mat

Příloha 2. Tabulky výsledků neuronových sítí

Tabulky výsledků neuronových sítí pro různý počet neuronů:

Tabulka výsledků 1

Počet neuronů	Bayesova metoda								
	Trénovací skupina dat			Testovací skupina dat					
	Průměr F1 [%]	Odchylka [%]	Průměr odchylek 5fold [%]	Průměr testovací F1 [%]	Odchylka [%]	Průměr senzitivity [%]	Odchylka [%]	Průměr specificity [%]	Odchylka [%]
1	92,31	0,476	0,073	78,96	0,540	68,73	3,188	95,37	0,304
2	92,84	0,804	0,203	81,40	0,914	67,27	5,183	96,88	0,666
3	93,52	0,562	0,144	82,76	1,555	70,18	8,610	97,06	1,159
4	93,90	0,579	0,124	82,91	0,335	70,00	4,853	97,14	0,768
5	94,27	0,540	0,161	82,65	0,824	62,18	2,619	98,28	0,325
6	94,46	0,623	0,145	83,01	1,376	65,09	6,479	97,99	0,551
7	94,60	0,506	0,107	84,03	1,242	69,82	5,906	97,68	0,513
8	94,70	0,671	0,116	83,94	0,609	67,09	4,186	98,05	0,578
9	95,02	0,451	0,174	83,97	1,672	69,09	5,102	97,77	0,411
10	95,01	0,420	0,072	84,42	1,074	71,27	3,994	97,62	0,523
11	95,14	0,549	0,140	84,48	0,883	71,45	3,726	97,62	0,362
12	95,20	0,378	0,184	84,36	1,321	70,91	6,894	97,67	0,554
13	95,29	0,339	0,077	84,59	1,279	73,09	4,481	97,43	0,364
14	95,35	0,539	0,095	82,90	1,589	66,55	7,369	97,72	0,553
15	95,59	0,318	0,232	82,18	0,764	64,18	6,606	97,77	0,823
16	95,66	0,460	0,081	84,59	1,768	75,27	5,800	97,11	0,368
17	95,72	0,356	0,102	83,89	0,771	74,18	5,167	96,95	0,458
18	95,77	0,369	0,126	84,01	3,410	76,18	13,023	96,78	0,673
19	95,96	0,440	0,053	83,72	1,261	73,64	5,641	96,95	0,656
20	95,89	0,516	0,106	82,44	1,389	67,45	3,931	97,33	0,374
21	95,93	0,512	0,107	84,42	1,088	73,64	5,492	97,27	0,680
22	96,04	0,364	0,094	83,27	0,769	70,73	3,175	97,19	0,398
23	95,91	0,267	0,097	83,76	1,444	74,36	6,845	96,86	0,588
24	96,07	0,410	0,136	83,59	0,793	72,00	5,545	97,14	0,674
25	96,12	0,535	0,124	83,82	1,620	74,36	8,753	96,91	0,686
26	96,01	0,426	0,131	83,28	1,589	74,91	7,941	96,56	0,690

27	96,08	0,628	0,083	83,79	1,066	75,09	7,941	96,77	0,842
28	96,07	0,424	0,061	82,41	2,199	72,73	9,599	96,51	0,541
29	96,11	0,382	0,075	83,64	1,467	76,00	4,836	96,54	0,189
30	96,08	0,427	0,114	82,18	2,033	69,45	10,730	96,95	0,856
31	96,15	0,523	0,115	84,31	0,888	75,09	5,552	96,99	0,698
32	96,21	0,299	0,110	82,01	1,124	66,91	5,552	97,23	0,457
33	96,09	0,526	0,077	83,28	1,399	73,64	4,591	96,74	0,367
34	96,11	0,501	0,151	83,70	1,228	77,45	7,751	96,37	0,669
35	96,19	0,517	0,110	83,51	1,923	72,91	8,940	96,98	1,135
36	96,26	0,407	0,103	84,71	0,922	83,45	3,931	95,93	0,388
37	96,21	0,374	0,090	83,42	0,810	71,64	6,146	97,12	0,727
38	96,29	0,539	0,030	84,04	0,911	76,18	4,518	96,70	0,355
39	96,11	0,407	0,047	83,28	1,897	71,82	8,814	97,06	0,603
40	96,17	0,552	0,110	84,52	1,434	79,45	7,862	96,46	0,530
41	96,24	0,537	0,093	83,81	1,087	77,45	7,312	96,41	0,740
42	96,19	0,525	0,082	82,81	1,735	73,09	5,982	96,61	0,250
43	96,22	0,439	0,086	83,91	1,412	76,00	9,634	96,70	0,886
44	96,19	0,480	0,087	83,08	1,960	74,00	9,262	96,62	0,646
45	96,20	0,447	0,075	82,32	1,021	69,27	3,878	96,98	0,450
46	96,23	0,535	0,117	84,14	1,408	79,82	10,333	96,24	0,988
47	96,14	0,594	0,189	83,34	0,887	73,82	7,698	96,75	0,885
48	96,10	0,491	0,099	83,03	1,191	71,82	8,720	96,93	0,901
49	96,10	0,354	0,108	84,30	1,591	74,73	7,054	97,06	0,657
50	96,09	0,415	0,179	83,12	2,352	73,45	12,237	96,77	0,889

Tabulka výsledků 2

Počet neuronů	LM metoda								
	Trénovací skupina dat			Testovací skupina dat					
	Průměr F1 [%]	Odchylka [%]	Průměr odchylek 5fold [%]	Průměr testovací F1 [%]	Odchylka [%]	Průměr senzitivity [%]	Odchylka [%]	Průměr specificity [%]	Odchylka [%]
1	87,53	6,517	11,072	76,68	0,755	91,71	0,438	89,49	1,952
2	92,59	0,197	0,617	79,41	0,350	89,19	0,581	91,83	0,587
3	93,30	0,158	0,816	79,13	0,881	90,63	0,696	91,40	0,548
4	93,65	0,314	0,664	80,53	0,936	92,25	0,876	92,03	0,567
5	93,50	0,230	0,744	80,77	1,607	90,09	0,943	92,52	0,578
6	93,97	0,214	0,628	80,28	0,466	93,87	0,400	91,61	0,488
7	93,72	0,140	0,581	81,08	1,818	90,99	1,245	92,56	0,503
8	93,95	0,119	0,729	81,32	0,657	91,17	0,731	92,70	0,541
9	94,27	0,278	0,674	81,16	0,984	93,69	0,870	92,19	0,395
10	94,00	0,257	0,726	82,07	1,809	91,71	1,273	93,04	0,622
11	94,06	0,129	0,549	82,29	1,374	90,63	1,154	93,34	0,460
12	94,22	0,393	0,684	81,39	2,790	93,15	2,145	92,33	0,614
13	94,26	0,109	0,598	81,60	2,460	93,33	1,766	92,46	0,278
14	94,26	0,198	0,415	81,16	2,179	92,79	1,658	92,28	0,244
15	94,25	0,139	0,562	81,25	0,859	92,79	0,564	92,40	0,460
16	94,44	0,198	0,770	82,43	1,064	91,35	0,960	93,33	0,857
17	94,49	0,091	0,687	82,05	0,725	92,61	0,770	92,91	0,593
18	94,45	0,359	0,760	81,06	2,106	92,43	1,749	92,28	0,525
19	94,43	0,119	0,646	82,48	0,997	92,97	0,828	93,10	0,631
20	94,47	0,219	0,586	80,56	1,955	94,41	1,361	91,66	0,494
21	94,65	0,177	0,609	82,56	1,325	92,07	1,230	93,28	0,681
22	94,52	0,191	0,729	82,66	1,787	92,43	1,451	93,26	0,539
23	94,67	0,155	0,503	82,89	0,802	90,45	0,978	93,73	0,600
24	94,36	0,334	0,682	82,50	0,696	90,63	0,802	93,49	0,471
25	94,55	0,308	0,575	82,20	1,918	92,25	1,465	93,02	0,348
26	94,65	0,201	0,697	82,35	1,595	93,51	1,074	92,93	0,935
27	94,56	0,165	0,732	82,76	1,359	92,25	1,217	93,36	0,664
28	94,44	0,217	0,655	82,85	0,948	92,61	0,740	93,38	0,679
29	94,61	0,119	0,597	82,79	0,622	91,89	0,547	93,46	0,598
30	94,56	0,171	0,581	81,49	1,451	91,35	1,237	92,75	0,513
31	94,52	0,175	0,710	81,59	0,633	93,69	0,423	92,46	0,423

32	94,69	0,121	0,490	82,62	1,724	93,69	1,138	93,05	0,232
33	94,72	0,180	0,496	82,16	0,970	92,79	0,817	92,94	0,894
34	94,55	0,216	0,667	81,96	0,820	93,69	0,615	92,68	1,011
35	94,56	0,223	0,549	81,75	1,639	93,87	1,075	92,51	0,555
36	94,47	0,233	0,667	82,19	1,070	91,35	0,832	93,18	0,623
37	94,58	0,348	0,483	82,10	0,699	92,25	0,241	93,01	0,587
38	94,74	0,099	0,429	83,23	1,096	90,99	0,844	93,84	0,634
39	94,65	0,227	0,693	81,96	1,972	92,07	1,691	92,89	0,464
40	94,73	0,175	0,573	83,18	0,626	91,17	0,494	93,79	0,649
41	94,85	0,284	0,659	83,53	0,576	91,53	0,501	93,94	0,525
42	94,64	0,170	0,918	81,75	1,730	92,25	1,440	92,75	0,783
43	94,55	0,234	0,623	82,87	0,429	92,43	0,374	93,42	0,627
44	94,46	0,153	0,675	82,79	1,217	92,43	1,000	93,36	0,492
45	94,55	0,152	0,754	82,98	1,085	92,97	0,742	93,39	1,036
46	94,81	0,258	0,616	82,16	1,018	92,43	1,075	92,99	0,416
47	94,64	0,114	0,763	82,95	1,234	91,71	0,798	93,57	0,872
48	94,54	0,182	0,637	81,59	0,904	93,15	0,947	92,54	0,415
49	94,69	0,246	0,790	83,16	0,904	91,17	0,662	93,78	0,867
50	94,85	0,280	0,746	82,73	1,774	91,35	1,340	93,47	0,751

Tabulka výsledků 3

Tabulky výsledků 20 cyklů pro vybraný počet vnitřních neuronů

Bayesova metoda pro 23 neuronů					Průměr
Train F1 [%]	Train stds [%]	Test F1 [%]	Test sens. [%]	Test spec. [%]	
95,97	0,621	82,45	90,99	93,41	
96,05	0,457	83,83	91,89	94,05	
95,89	0,659	83,34	90,09	94,05	
96,27	0,481	83,76	87,39	94,69	
96,17	0,149	83,10	81,98	95,18	
96,22	0,387	83,87	90,99	94,21	
96,19	0,431	82,87	90,99	93,65	
96,06	0,635	83,97	89,19	94,53	
95,79	0,308	84,32	90,99	94,45	
96,07	0,583	84,42	86,49	95,18	
96,05	0,473	81,85	88,29	93,49	
96,21	0,164	84,09	81,08	95,82	
96,11	0,432	84,72	89,19	94,94	
96,20	0,522	85,23	90,99	94,94	
96,21	0,621	83,35	86,49	94,61	
95,96	0,420	84,32	85,59	95,26	
96,10	0,558	83,10	85,59	94,61	
96,02	0,418	83,34	90,09	94,05	
95,85	0,400	82,28	91,89	93,17	
96,02	0,667	84,69	81,98	95,98	
96,07	0,469	83,64	88,11	94,51	Průměr

Tabulka výsledků 4

LM metoda pro 17 neuronů					
Train F1 [%]	Train std [%]	Test F1 [%]	Test sens. [%]	Test spec. [%]	
94,72	0,596	84,12	91,89	94,21	
94,49	0,496	84,32	90,99	94,45	
94,28	0,486	83,42	88,29	94,37	
94,30	1,021	84,17	88,29	94,77	
94,58	1,111	84,22	90,09	94,53	
94,50	0,489	83,73	90,99	94,13	
94,49	0,666	83,48	90,09	94,13	
94,20	0,698	78,13	96,40	89,71	
94,54	0,704	83,74	93,69	93,73	
94,45	0,785	81,58	92,79	92,60	
94,22	0,447	78,25	95,50	89,95	
93,92	0,800	81,21	91,89	92,52	
94,52	0,611	81,95	93,69	92,68	
94,15	0,625	80,74	82,88	93,73	
94,44	0,410	82,69	91,89	93,41	
94,44	0,235	81,71	92,79	92,68	
94,35	0,909	80,76	94,59	91,80	
94,34	0,707	83,34	90,09	94,05	
94,67	0,565	81,55	93,69	92,44	
93,93	0,668	82,45	90,99	93,41	
94,38	0,651	82,28	91,58	93,17	Průměr